



ΠΑΝΕΠΙΣΤΗΜΙΟ
ΙΩΑΝΝΙΝΩΝ

ΠΑΝΕΠΙΣΤΗΜΙΟ ΙΩΑΝΝΙΝΩΝ

ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΤΗΛΕΠΙΚΟΙΝΩΝΙΩΝ

ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

ΤΕΧΝΙΚΕΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΤΑ ΑΣΥΡΜΑΤΑ ΔΙΚΤΥΑ

Ιωάννης Ηλίας

Επιβλέπων: Γεώργιος Τσουμάνης

Άρτα, Ιανουάριος, 2022

MACHINE LEARNING TECHINQUES IN WIRELESS NETWORKS

Εγκρίθηκε από τριμελή εξεταστική επιτροπή

Άρτα, 28 Ιανουαρίου 2022

ΕΠΙΤΡΟΠΗ ΑΞΙΟΛΟΓΗΣΗΣ

1. Επιβλέπων καθηγητής

Γεώργιος Τσουμάνης

2. Μέλος επιτροπής

Κωνσταντίνος Αγγέλης

3. Μέλος επιτροπής

Βασίλειος Χαριλόγης

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Δήλωση μη λογοκλοπής

Δηλώνω υπεύθυνα και γνωρίζοντας τις κυρώσεις του Ν. 2121/1993 περί Πνευματικής Ιδιοκτησίας, ότι η παρούσα μεταπτυχιακή εργασία είναι εξ ολοκλήρου αποτέλεσμα δικής μου ερευνητικής εργασίας, δεν αποτελεί προϊόν αντιγραφής ούτε προέρχεται από ανάθεση σε τρίτους. Όλες οι πηγές που χρησιμοποιήθηκαν (κάθε είδους, μορφής και προέλευσης) για τη συγγραφή της περιλαμβάνονται στη βιβλιογραφία.

Ηλίας Ιωάννης

Υπογραφή

ΕΥΧΑΡΙΣΤΙΕΣ

Θα ήθελα να ευχαριστήσω την οικογένεια μου για την αέναη στήριξη που μου παρέχει σε όλο αυτό το ταξίδι της εκπαίδευσης μου, και όχι μόνο, θα ήθελα επίσης να ευχαριστήσω τον επιβλέπων καθηγητή μου κύριο Γεώργιο Τσουμάνη για την βοήθεια και την κατανόηση που μου παρείχε καθόλη την διάρκεια συγγραφής και έρευνας για την παρούσα πτυχιακή εργασία.

ΠΕΡΙΛΗΨΗ

Η παρούσα πτυχιακή εργασία έχει ως αντικείμενο την έρευνα η οποία εστιάζει στο πεδίο της Μηχανικής Μάθησης και των Ασύρματων Δικτύων. Πιο συγκεκριμένα ασχολείται με το ερευνητικό έργο επιστημόνων του κλάδου της Πληροφορικής και πραγματεύεται ζητήματα όπως η βελτίωση της δρομολόγησης σε δίκτυα MANET, σε δίκτυα Delay Tolerant, σε δίκτυα τα οποία παρουσιάζουν Elephant Flows, σε IoT δίκτυα και σε δίκτυα Software Defined με την χρήση τεχνικών Μηχανικής Μάθησης. Επιπροσθέτως γίνεται ανάλυση του πως η Μηχανική Μάθηση θα μπορούσε να βοηθήσει στην ασφάλεια από επιθέσεις spoofing σε 5G δίκτυα, στην πρόβλεψη της κάλυψης σε δίκτυα τηλεπικοινωνιών καθώς και παρουσιάζεται η χρήση του Edge Learning στον κλάδο.

Λέξεις-κλειδιά: Μηχανική Μάθηση, Ασύρματα Δίκτυα, Τεχνητά Νευρωνικά Δίκτυα, Διαδίκτυο των Πραγμάτων, 5G Δίκτυα.

ABSTRACT

The present thesis focuses on research in the field of Machine Learning and Wireless Networks. Specifically, this thesis deals with the research work of IT scientists and more specifically it deals with issues such as the improvement of routing in MANET networks, in Delay Tolerant Networks, in networks that present elephant flows in IoT networks and in Software Defined networks using Machine Learning techniques. In addition, there is an analysis of how Machine Learning could help in security against spoofing attacks on 5G networks, on the provision of coverage in telecommunications networks as well as the use of Edge Learning in the industry.

Keywords: Machine Learning, Wireless Networks, Neural Networks, Internet of things, 5G Networks.

ΠΙΝΑΚΑΣ ΠΕΡΙΕΧΟΜΕΝΩΝ

Περιεχόμενα

ΕΥΧΑΡΙΣΤΙΕΣ.....	6
ΠΕΡΙΛΗΨΗ	7
ABSTRACT	8
ΠΙΝΑΚΑΣ ΠΕΡΙΕΧΟΜΕΝΩΝ	9
ΚΑΤΑΛΟΓΟΣ ΠΙΝΑΚΩΝ	11
ΚΑΤΑΛΟΓΟΣ ΕΙΚΟΝΩΝ	12
ΠΙΝΑΚΑΣ ΣΥΝΤΟΜΟΓΡΑΦΙΩΝ	13
1 Έννοιες ασυρμάτων δικτύων	1
1.1 Βασικές έννοιες των δικτύων.....	1
1.1.1 Ορισμός δικτύων και διαδικτύου	1
1.1.2 Δίκτυα LAN και WAN.....	1
1.1.3 Ασύρματα δίκτυα.....	2
1.1.4 Ορισμός δρομολόγησης.....	2
1.1.5 Κατηγορίες πρωτοκόλλων δρομολόγησης.....	2
2 Έννοιες Μηχανικής Μάθησης.....	4
2.1 Ιστορική αναδρομή.....	4
2.1.1 Ορισμός της Τεχνητής Νοημοσύνης.....	4
2.1.2 Πως ξεκίνησε η ιδέα της Τεχνητής Νοημοσύνης.....	4
2.1.3 Ορισμός της Μηχανικής Μάθησης.....	5
2.1.4 Ιστορική αναδρομή της Μηχανικής Μάθησης.....	6
2.2 Το πεδίο της Μηχανικής Μάθησης	13
2.2.2 Βασικές προκλήσεις της Μηχανικής Μάθησης.....	17
3 Εφαρμογή τεχνικών Μηχανικής Μάθησης με σκοπό την βελτίωση της δρομολόγησης	24
3.1 Βελτίωση της απόδοσης της δρομολόγησης σε δίκτυα MANET.....	24
3.2 Πρόβλεψη σε πραγματικό χρόνο του τύπου ενός ασύρματου δικτύου και επιλογή του καλύτερου επόμενου βήματος (hop)	27
3.3 Τεχνικές ταξινόμησης σε Delay Tolerant δίκτυα με σκοπό την βελτίωση της δρομολόγησης.....	31

3.4	Πρόβλεψη σε πραγματικό χρόνο τεράστιων ποσοτήτων δεδομένων σε κανάλια για καλύτερη δρομολόγηση πακέτων	35
3.5	Χρήση μοντέλων μίξης με σκοπό την δρομολόγηση σε Opportunistic IoT δίκτυα.....	37
3.6	Βελτίωση της δρομολόγησης με επίκεντρο την ενέργεια σε ασύρματα δίκτυα με χρήση Support Vector Machines.....	39
3.7	Χρήση τεχνικών Μηχανικής Μάθησης σε δίκτυα Software Defined.	41
4	Λοιπές χρήσεις της Μηχανικής Μάθησης στα δίκτυα.....	45
4.1	Χρήσεις του Edge Learning στα ασύρματα δίκτυα	45
4.2	Πρόβλεψη της κάλυψης σε ένα ασύρματο δίκτυο	50
4.3	Αύξηση της ασφάλειας σε δίκτυα 5G με χρήση τεχνικών Μηχανικής Μάθησης.....	52
5	Συμπεράσματα.....	59
5.1	Συμπεράσματα	59
	Βιβλιογραφία.....	60

ΚΑΤΑΛΟΓΟΣ ΠΙΝΑΚΩΝ

Πίνακας 1. Καταστάσεις για την πρόβλεψη της κινητικότητας των κόμβων... 26

Πίνακας 2. Οι κλάσεις που δημιουργήθηκαν..... 29

ΚΑΤΑΛΟΓΟΣ ΕΙΚΟΝΩΝ

Εικόνα 1: Παράδειγμα δικτύου	2
Εικόνα 2: Σκαρίφημα κεντριοποιημένου τύπου δρομολόγησης.....	4
Εικόνα 3: Ο Alan Matheson Turing στην ηλικία των δεκαέξι ετών	5
Εικόνα 4: Ένας νευρώνας με τα διαφορετικά συστατικά του	7
Εικόνα 5: Ο Arthur Lee Samuel.....	8
Εικόνα 6: Ένας υπολογιστής IBM704 στην NASA TO 1957	9
Εικόνα 7: Το Stanford Cart το έτος 1979	10
Εικόνα 8: Για $k=5$ ο αλγόριθμος χωρίζει το σετ δεδομένων σε πέντε ομάδες και κάνει πέντε επαναλήψεις επιλέγοντας κάθε φορά διαφορετικό training test και test set	20
Εικόνα 9: Παράδειγμα πίνακα σύγχυσης.....	21
Εικόνα 10: Επικοινωνία του αστροναύτη με τον σταθμό στην Γη	28
Εικόνα 11: Τα σημεία τα οποία είναι παρόμοια βρίσκονται κοντά το ένα στο άλλο	31
Εικόνα 12: Δένδρα απόφασης για το πρόβλημα του Play Tennis.....	34
Εικόνα 13: Γραφική απεικόνιση του αλγόριθμου SMV	40
Εικόνα 14: Η απόδοση στο training set και στο test set	44
Εικόνα 15: Η απόδοση των σχημάτων δρομολόγησης.....	45
Εικόνα 16: Η πολυεπίπεδη αρχιτεκτονική για την χρήση Μηχανικής Μάθησης μέσα στο δίκτυο	47
Εικόνα 17: Η απόδοση του πειράματος.	50
Εικόνα 18: Το Νευρωνικό Δίκτυο που χρησιμοποιήθηκε	51
Εικόνα 19: Τα αποτελέσματα των προβλέψεων του Νευρωνικού Δικτύου και τα αποτελέσματα υπολογισμένα από προσομοίωσης Monte Carlo.....	52
Εικόνα 20: Σύγκριση κλασσικών στατικών τεχνικών αυθεντικοποίησης με έξυπνες τεχνικές αυθεντικοποίησης	59

ΠΙΝΑΚΑΣ ΣΥΝΤΟΜΟΓΡΑΦΙΩΝ

MLQU.....Machine Learning aided load balance routing schemes considering Queue Utilization

TEI-H.....Deep Learning aided balance routing schemes considering Queue Utilization

MSE..... Mean Square Error

LAN..... Local Area Network

WAN.....Wide Area Network

MLP..... Multi-Layer Perceptron

1 Έννοιες ασυρμάτων δικτύων

1.1 Βασικές έννοιες των δικτύων

Στο παρόν κεφάλαιο παρουσιάζονται οι βασικές έννοιες των δικτύων.

1.1.1 Ορισμός δικτύων και διαδικτύου

Ένα δίκτυο (βλ. Εικόνα 1) [1] ονομάζεται μία ομάδα υπολογιστικών μηχανών, οι οποίες επικοινωνούν ανταλλάσσοντας πόρους. Η επικοινωνία αυτή, παρέχεται μέσω των κόμβων του δικτύου. Μεγάλο ρόλο στην επίτευξη της επικοινωνίας διαδραματίζουν τα επικοινωνιακά πρωτόκολλα σε συνδυασμό με τις ψηφιακές διασυνδέσεις. Τα πρωτόκολλα επικοινωνίας αποτελούνται από ένα σύστημα κανόνων οι οποίοι επιτρέπουν σε δύο ή παραπάνω οντότητες να επικοινωνήσουν μέσω μετάδοσης δεδομένων. Κόμβος ονομάζεται το σημείο εκείνο στο δίκτυο το οποίο λειτουργεί ως σημείο διασύνδεσης, έχει την ικανότητα να λάβει, να προωθήσει, να αποθηκεύσει και να δημιουργήσει πακέτα. Πακέτα ονομάζονται μικρές ομάδες δεδομένων οι οποίες μεταφέρονται στο δίκτυο και μεταφέρουν δεδομένα από κόμβο σε κόμβο.


Το διαδίκτυο είναι ένα παγκόσμιο σύστημα διασυνδεδεμένων δικτύων υπολογιστών. Το διαδίκτυο ανήκει στην κατηγορία WAN καθώς ενώνει όλα τα δίκτυα και τους επιτρέπει να επικοινωνήσουν. [2]

1.1.2 Δίκτυα LAN και WAN

Τα δίκτυα χωρίζονται σε δύο βασικές κατηγορίες, τα LAN και τα WAN.

LAN (Local Area Network) ονομάζονται τα δίκτυα τα οποία είναι περιορισμένα σε μια συγκεκριμένη περιοχή, όπως ένα γραφείο, ένα σπίτι ή ένα Campus. Σε τέτοια δίκτυα την σύνδεση στο διαδίκτυο την παρέχει ένας δρομολογητής, ένα hub ή ένα switch, επίσης μπορεί αν υπάρχουν και αναμεταδότες και σημεία πρόσβασης στο δίκτυο. Η σύνδεση μπορεί να γίνει ασύρματα καθώς και με κάποιο καλώδιο (π.χ. ethernet).

WAN (Wide Area Network) είναι τα δίκτυα τα οποία δεν είναι περιορισμένα σε μία μόνο περιοχή αλλά καλύπτουν αρκετές περιοχές. Τα WAN συνήθως αποτελούνται από πολλά LAN δίκτυα τα οποία είναι συνδεδεμένα στο διαδίκτυο. Ένα παράδειγμα, είναι ένα δίκτυο WAN μιας εταιρείας το οποίο μπορεί να επεκτείνεται σε όλο τον κόσμο. [3]



Εικόνα 1: Παράδειγμα δικτύου

1.1.3 Ασύρματα δίκτυα

Τα ασύρματα δίκτυα είναι μια κατηγορία δικτύων η οποία χρησιμοποιεί ασύρματες συνδέσεις για την επικοινωνία των κόμβων. Ένα χαρακτηριστικό παράδειγμα φαίνεται στην Εικόνα 1 καθώς συσκευές όπως ένα κινητό, ένα laptop κ.τ.λ. συνδέονται ασύρματα με τον δρομολογητή χωρίς την χρήση κάποιου καλωδίου. Η χρήση των ασύρματων δικτύων είναι ικανή να γλιτώσει από (οικονομική) σπατάλη οργανισμούς, επιχειρήσεις κ.α. καθώς δεν χρειάζεται η εγκατάσταση καλωδίων σε κάποιο κτίριο για να γίνει η επικοινωνία. [4]

1.1.4 Ορισμός δρομολόγησης

Δρομολόγηση ονομάζεται η διαδικασία κατά την οποία σε ένα ή περισσότερα δίκτυα επιλέγεται η καλύτερη διαδρομή για να μεταφερθούν τα πακέτα δεδομένων από τον κόμβο αποστολής στον κόμβο προορισμού. [5]

1.1.5 Κατηγορίες πρωτοκόλλων δρομολόγησης


Πρωτόκολλο δρομολόγησης ονομάζεται το πρωτόκολλο εκείνο το οποίο περιγράφει τον τρόπο με τον οποίο οι δρομολογητές θα επικοινωνούν μεταξύ τους, θα μεταφέρουν δεδομένα και θα στελεχώνουν την επικοινωνία μεταξύ των κόμβων ενός δικτύου. Τα

πρωτόκολλα μπορούν να χωριστούν σε στατικά και δυναμικά. Στα στατικά πρωτόκολλα δρομολόγησης, οι πίνακες δρομολόγησης διαμορφώνονται χειροκίνητα από τους διαχειριστές του δικτύου και χρησιμοποιούνται ως εμπιστευτικές προσωπικές πληροφορίες οι οποίες δεν είναι ορατές σε όλο το δίκτυο. Στα δυναμικά πρωτόκολλα από την άλλη, οι δρομολογητές ανταλλάσσουν τους πίνακες δρομολόγησης αυτοματοποιημένα και συχνά, οι πίνακες δρομολόγησης, ενημερώνονται μέσω κάποιων αλγορίθμων με αποτέλεσμα στους πίνακες τους οποίους έχουν δημιουργηθεί να υπάρχει πρόσβαση σε πάνω από έναν δρομολογητές. Δύο πρωτόκολλα τα οποία θα αναλυθούν είναι το κεντρικοποιημένο (Centralized Routing Protocol) και το πρωτόκολλο κατανεμημένης δρομολόγησης (Distributed Routing Protocol).

Πίνακας δρομολόγησης ονομάζεται ένας πίνακας δεδομένων ο οποίος βρίσκεται αποθηκευμένος σε έναν δρομολογητή ή σε έναν πάροχο δικτύου και περιέχει τις διαδρομές που ακολουθούν τα δεδομένα για να φτάσουν σε έναν κόμβο προορισμό, σε κάποιες περιπτώσεις κάποιες μετρικές (π.χ. απόσταση), καθώς και πληροφορίες για την τοπολογία του δικτύου.

Σε ένα κεντρικοποιημένο τύπο δρομολόγησης (βλ. Εικόνα 2) σχεδιάζεται ένας κεντρικός κόμβος (Central Node) ο οποίος συγκεντρώνει πληροφορίες από τους υπόλοιπους κόμβους του δικτύου. Με αυτό τον τρόπο ο κεντρικός κόμβος έχει συνολική επίγνωση για την κατάσταση του δικτύου. Μια άλλη αρμοδιότητα του κεντρικού κόμβου είναι ο υπολογισμός της βέλτιστης διαδρομής των πακέτων στο δίκτυο από τον κάθε κόμβο προς όλους τους πιθανούς κόμβους προορισμού χρησιμοποιώντας αλγόριθμους. Στην συνέχεια προωθεί τον πίνακα δρομολόγησης σε κάθε κόμβο και ταυτόχρονα τον αποθηκεύει σε μια βάση δεδομένων για διευκόλυνση της διαχείρισης του δικτύου.

Σε ένα πρωτόκολλο κατανεμημένης δρομολόγησης κάθε κόμβος ενημερώνεται για την κατάσταση του δικτύου από τους υπόλοιπους κόμβους του ίδιου δικτύου και αποθηκεύει τις πληροφορίες σε μία τοπική βάση δεδομένων. Με βάση τις πληροφορίες που έχουν συγκεντρωθεί, ο κάθε κόμβος εκτελεί έναν αλγόριθμο με σκοπό τον υπολογισμό του πίνακα δρομολόγησης. Μετά τον υπολογισμό αυτό, οι κόμβοι με την σειρά τους θα ενημερώσουν τους γειτονικούς τους κόμβους. [6]



Εικόνα 2: Σκαρίφημα κεντρικοποιημένου τύπου δρομολόγησης

2 Έννοιες Μηχανικής Μάθησης

2.1 Ιστορική αναδρομή

Στο παρόν υποκεφάλαιο γίνεται μια ιστορική αναδρομή στην τεχνητή νοημοσύνη και την μηχανική μάθηση.


2.1.1 Ορισμός της Τεχνητής Νοημοσύνης

Υπάρχουν αρκετοί ορισμοί για την απόδοση του όρου της τεχνητής νοημοσύνης (Artificial Intelligence) οι οποίοι έχουν προκύψει τις τελευταίες δεκαετίες. Ένας κατανοητός ορισμός παρέχεται από τον John McCarty από το άρθρο του “What is Artificial Intelligence” ο οποίος είναι ο εξής: “Είναι η επιστήμη και η μηχανική του να δημιουργείς ευφυείς μηχανές, δηλαδή ειδικότερα νοήμονα υπολογιστικά προγράμματα. Σχετίζεται με το εγχείρημα της χρήσης υπολογιστών για την κατανόηση της νοημοσύνης, αλλά η τεχνητή νοημοσύνη δεν χρειάζεται να περιορίζεται σε μεθόδους οι οποίες είναι βιολογικά παρατηρήσιμες” [7]

2.1.2 Πως ξεκίνησε η ιδέα της Τεχνητής Νοημοσύνης

Η ιδέα προήλθε από τον λεγόμενο και ως “πατέρα” της τεχνητής νοημοσύνης Alan Turing (βλ. Εικόνα 3) [8] το 1950 στο έργο του “Computing Machinery and Intelligence” όπου έκανε την εξής ερώτηση: “Can machines think?” δηλαδή “Μπορούν οι μηχανές να σκεφτούν;”. Αποτέλεσμα αυτού ήταν η πρόταση ενός test το οποίο στις μέρες μας είναι γνωστό ως το λεγόμενο “Turing Test”. Το Turing Test είναι μια διαδικασία στην οποία ένας άνθρωπος συνομιλεί με μία μηχανή με κείμενο, αλλά δεν γνωρίζει εκ των προτέρων αν οι απαντήσεις προέρχονται από κάποιον άνθρωπο ή μία μηχανή. Αν του μιλάει η μηχανή και

δεν είναι ικανός να καταλάβει την διαφορά (σαν να του μιλάει κάποιος άνθρωπος) τότε αυτή η μηχανή έχει “νοημοσύνη” και περνά το Turing Test. [9]



Εικόνα 3: Ο Alan Matheson Turing στην ηλικία των δεκαέξι ετών

2.1.3 Ορισμός της Μηχανικής Μάθησης

Πολλοί είναι οι ορισμοί οι οποίοι θα μπορούσαν να περιγράψουν την Μηχανική Μάθηση, δύο από αυτούς περιγράφονται παρακάτω:

Η Μηχανική Μάθηση είναι το πεδίο το οποίο δίνει στους υπολογιστές την ικανότητα να μαθαίνουν χωρίς να είναι προγραμματισμένοι για αυτό τον σκοπό. [10]

Μηχανική μάθηση ονομάζεται ο κλάδος της τεχνητής νοημοσύνης και της επιστήμης των υπολογιστών ο οποίος είναι εστιασμένος στην χρήση των δεδομένων και των αλγορίθμων με σκοπό την μίμηση του τρόπου μάθησης των ανθρώπων, πράγμα το οποίο έχει ως σκοπό την βελτίωση της ακρίβειάς τους. [11]


2.1.4 Ιστορική αναδρομή της Μηχανικής Μάθησης

Η ιδέα της Μηχανικής Μάθησης βασίστηκε σε ένα μοντέλο αλληλεπίδρασης εγκεφαλικών κυττάρων του 1949 γραμμένο από τον ψυχολόγο Donald Hebb, το οποίο ήταν περιεχόμενο του βιβλίου “The Organization of Behavior”.

Ο Hebb έγραψε: “Όταν ένα κύτταρο επανειλημμένα πυροδοτεί ένα άλλο, ο άξονας του πρώτου κυττάρου αναπτύσσει συνάψεις (ή τις κάνει δυνατότερες εάν υπάρχουν ήδη) στο σημείο επαφής με το σώμα του δεύτερου κυττάρου”. Χρησιμοποιώντας αυτή την ιδέα σε έννοιες της Τεχνητής Νοημοσύνης και των τεχνητών νευρώνων, το μοντέλο του μπορεί να περιγραφεί ως ένας τρόπος εναλλαγής των σχέσεων σε τεχνητούς νευρώνες. Η σχέση μεταξύ δύο νευρώνων δυναμώνει όταν αυτοί ενεργοποιούνται την ίδια στιγμή και αποδυναμώνεται όταν ενεργοποιούνται ξεχωριστά. [12]

2.1.4.1 Ο Νευρώνας των McCulloch-Pitts

Το 1940 ο νευροφυσιολόγος Warren McCulloch και ο επιστήμονας της λογικής (logician) Walter Pitts συνεργάστηκαν με σκοπό να φτιάξουν ένα μοντέλο εμπνευσμένο από την δομή και τη λειτουργία του εγκεφάλου. Ένα βασικό δομικό συστατικό του εγκεφάλου είναι οι νευρώνες (βλ. Εικόνα 4) [13], οι οποίοι ουσιαστικά είναι νευρικά κύτταρα τα οποία δημιουργούν ένα δίκτυο μεταξύ τους μέσω του οποίου επικοινωνούν και μεταφέρουν πληροφορίες. Μια τέτοια προσπάθεια μαθηματικής αναπαράστασης ενός δικτύου από νευρώνες είναι ο νευρώνας των McCulloch-Pitts. Τα δίκτυα αυτά τα οποία αναπαριστούν κατά κάποιον τρόπο την λειτουργία των νευρώνων ονομάζονται Τεχνητά Νευρωνικά Δίκτυα (ΤΝΔ). Ο νευρώνας των McCulloch-Pitts δέχεται κάποιες αριθμητικές εισόδους (όπως ένας νευρώνας δέχεται ηλεκτρικά σήματα) και μέσα από κάποιες πράξεις εξάγονται κάποια αποτελέσματα σχετικά με τη χρονική στιγμή κατά την οποία ο νευρώνας είναι ενεργός άρα, η πληροφορία μεταφέρεται από τον νευρώνα και αντίστοιχα όταν ο νευρώνας δεν είναι ενεργός τότε η πληροφορία δεν χρειάζεται να μεταφερθεί. [14]



Εικόνα 4: Ένας νευρώνας με τα διαφορετικά συστατικά του

2.1.4.2 Το παιχνίδι της Ντάμας

Στην συνέχεια την δεκαετία του 50 ο Arthur Samuel (βλ. Εικόνα 5) [15] όπου εκείνη την περίοδο εργαζόταν στην IBM, δημιούργησε ένα πρόγραμμα το οποίο έπαιζε το παιχνίδι της ντάμας. Λόγω περιορισμένη μνήμης ο Samuel χρησιμοποίησε μια τεχνική γνωστή ως κλάδεμα Άλφα-βήτα (Alpha-beta pruning). Ο σχεδιασμός του περιλάμβανε μια συνάρτηση βαθμολόγησης η οποία χρησιμοποιούσε τις θέσεις των καρτών της τράπουλας. Η συνάρτηση βαθμολόγησης προσπαθούσε να βρει την πιθανότητα νίκης της κάθε πλευρά. Το πρόγραμμα διάλεγε την επόμενη του κίνηση χρησιμοποιώντας μια στρατηγική minimax η οποία εξελίχθηκε στον αλγόριθμο Minimax. Στην συνέχεια ο Samuel δημιούργησε μηχανισμούς τους οποίους χρησιμοποίησε για να βελτιώσει το αρχικό του πρόγραμμα. Δημιούργησε κάτι που λεγόταν “Rote Learning”, το πρόγραμμα αυτό κατέγραφε όλες τις θέσεις των φύλλων που είχαν παιχτεί και συνδύαζε αυτή την γνώση με την συνάρτηση βαθμολόγησης. Εκείνη την εποχή και πιο συγκεκριμένα το 1959 χρησιμοποιήθηκε για πρώτη φορά ο όρος “Μηχανική Μάθηση” από τον ίδιο στο “IBM journal of Research and Development”. [10]



Εικόνα 5: Ο Arthur Lee Samuel

2.1.4.3 To Perceptron.

Στην συνέχεια το 1957, ο Frank Rosenblatt στο Αεροναυτικό Εργαστήριο του Cornell συνδύασε το μοντέλο των αλληλεπιδράσεων των εγκεφαλικών κυττάρων των McCulloch-Pitts με τις αρχικές προσπάθειες Μηχανικής Μάθησης του Arthur Samuel και δημιούργησε το “Perceptron”. Το Perceptron αρχικά ήταν σχεδιασμένο σαν μια μηχανή και όχι σαν ένα πρόγραμμα. Το λογισμικό είχε σχεδιαστεί για το IBM704 (βλ. Εικόνα 6) [16] αλλά χρησιμοποιήθηκε σε μια ειδικά κατασκευασμένη μηχανή εν’ονόματι “Mark 1 perceptron”. Η μηχανή αυτή είχε κατασκευαστεί με σκοπό την αναγνώριση εικόνας.

Ο Mark 1 perceptron ήταν ο πρώτος επιτυχημένος νευρο-υπολογιστής και όπως είναι φυσικό είχε προβλήματα. Ένα από τα προβλήματα που είχε ήταν πως δεν μπορούσε να αναγνωρίσει πολλά είδη από οπτικά μοτίβα(π.χ. πρόσωπα). Αυτό προκάλεσε απογοήτευση και καθυστέρηση στον τομέα της έρευνας των Νευρωνικών Δικτύων, γεγονός το οποίο είχε ως αποτέλεσμα την απογοήτευση των επενδυτών, των επενδυτικών ιδρυμάτων και την πολυετή παύση της χρηματοδότησης και κατ’έπείκταση την μερική παύση της προόδου του κλάδου της μηχανικής μάθησης. [17]



Εικόνα 6: Ένας υπολογιστής IBM704 στην NASA TO 1957

2.1.4.4 Ο αλγόριθμος του κοντινότερου Γείτονα

Το 1967 αφού είχε δημιουργηθεί ο αλγόριθμος του Κοντινότερου Γείτονα, σημάνθηκε η αρχή της Αναγνώρισης Προτύπων, ενός κλάδου της Μηχανικής Μάθησης που αυτοματοποιημένα αναγνωρίζει μοτίβα στα δεδομένα και μπορεί να χρησιμοποιηθεί για επεξεργασία εικόνας, λόγου κ.α. [18]. Ο αλγόριθμος πρώτα χρησιμοποιήθηκε για να βρεθεί μια λύση στο πρόβλημα του “περιοδεύοντος πωλητή”. Ο αλγόριθμος θα αναλυθεί σε επόμενο κεφάλαιο.

Το πρόβλημα του περιοδεύοντος πωλητή (traveling salesman problem) είναι το παρακάτω: “Δοθείσας μιας λίστας από πόλεις και αποστάσεις της μίας πόλης από την άλλη, ποια είναι η μικρότερη πιθανή διαδρομή με την οποία ο πωλητής επισκέπτεται ακριβώς μια πόλη ακριβώς μια φορά και επιστρέφει στην αφετηρία του ” [19].

2.1.4.5 Τεχνολογική ανάπτυξη από την δεκαετία του 70 και του 80

Το 1979 ο Moravec στο πανεπιστήμιο του Stanford ανέπτυξε το “Stanford Cart” (βλ. Εικόνα 7) [20] το οποίο ήταν ένα ρομπότ το οποίο είχε ρόδες και ήταν ικανό να κινείται μέσα σε χώρους με εμπόδια, αποκτούσε την γνώση του από ένα σύστημα πλοήγησης που ως βάση είχε σήματα τα οποία λάμβανε από αισθητήρες. Το καρότσι ■ ανίχνευε το περιβάλλον του χρησιμοποιώντας ένα σύνολο από 9 εικόνες οι οποίες ήταν λαμβάνονταν από μία κάμερα

που υπήρχε στο πλάι και στη συνέχεια τις επεξεργαζόταν κάποιο λογισμικό και λάμβανε αποφάσεις σχετικά με την κατεύθυνση κίνησης του. [21]



Εικόνα 7: To Stanford Cart το έτος 1979

Το 1986 ο Gerald Dejong και ο Raymond Mooney παρουσίασαν μια τεχνική με όνομα “Explanation-Based Learning” (EBL), δηλαδή μάθηση με βάση την επεξήγηση. Πρόκειται για μια προσέγγιση της Μηχανικής Μάθησης όπου ένα πρόγραμμα αναλύει τα δεδομένα εκπαίδευσης και δημιουργεί και ακολουθεί έναν γενικό κανόνα απορρίπτοντας δεδομένα τα οποία δεν είναι σημαντικά. [22]

Το 1987 ο Terrence Sejnowski και ο Charles Rosenberg δημιούργησαν το NETalk ένα ΤΝΔ το οποίο εκπαιδευόταν να προφέρει αγγλικές λέξεις, αποτελούταν από τριακόσιους νευρώνες οι οποίοι ήταν οργανωμένοι σε τρία επίπεδα και σε ένα επίπεδο εισόδου. Στο

επίπεδο εισόδου εισάγονταν οι λέξεις και στα επίπεδα εξόδου ακουγόταν ο ήχος από την λέξη που προφερόταν. [23]

2.1.4.6 Ο διαχωρισμός της Μηχανικής Μάθησης και της τεχνητής νοημοσύνης

Την δεκαετία του 70 και στα τέλη της δεκαετίας του 80 οι ερευνητές που είχαν ως αντικείμενο έρευνας την Τεχνητή Νοημοσύνη επικεντρώθηκαν (στην επίλυση προβλημάτων) με προσεγγίσεις οι οποίες είχαν ως επίκεντρο την λογική και όχι τους αλγορίθμους. Επίσης, η έρευνα για τα Νευρωνικά Δίκτυα εγκαταλείφθηκε από τους ερευνητές προκαλώντας τον διαχωρισμό μεταξύ Μηχανικής Μάθησης και Τεχνητής Νοημοσύνης. Η Μηχανική Μάθηση έως τότε χρησίμευε ως πρόγραμμα εκπαίδευσης για εφαρμογές της Τεχνητής Νοημοσύνης.

Ο τομέας της Μηχανικής Μάθησης τότε αποτελούταν από μια μεγάλη ομάδα από ερευνητές και τεχνικούς και λόγω του διαχωρισμού των κλάδων, για μια δεκαετία περίπου δεν είχε προβλήματα. Ο σκοπός άλλαξε και από την εκπαίδευση των αλγορίθμων Τεχνητής Νοημοσύνης στην επίλυση προβλημάτων και παροχή άλλων υπηρεσιών. Ο κλάδος πλέον είχε επικεντρωθεί στην χρήση τακτικών που χρησιμοποιούνταν στις πιθανότητες και την στατιστική. Μέχρι την δεκαετία του 90 ο τομέας της μηχανικής μάθησης ήταν επικεντρωμένος για άλλη μια φορά στα Νευρωνικά Δίκτυα, όμως με την έναρξη της δεκαετίας του 90 άκμασε, καθώς λόγω του διαδικτύου αυξήθηκε η δημοτικότητά του λόγω της εύκολης πρόσβασης σε δεδομένα και της ικανότητας να μοιράζεται υπηρεσίες μέσω του διαδικτύου. [24]

2.1.4.7 Αναγνώριση Λόγου

Το 1997 ο Jürgen Schmidhuber και ο Sepp Hochreiter παρουσίασαν μια τεχνική με όνομα Long Short-Term Memory (LSTM) [25], που στην ουσία ήταν ένα Νευρωνικό Δίκτυο το οποίο μπορούσε να εκπαιδευτεί για διαδικασίες οι οποίες απαιτούσαν μνήμη για τα γεγονότα τα οποία συνέβησαν στο παρελθόν, τα οποία ίσως να ήταν χιλιάδες διακριτά βήματα νωρίτερα, πράγμα πολύ σημαντικό για την ομιλία. Η τεχνική αυτή χρησιμοποιείται και σήμερα για την εκπαίδευση αλγόριθμων Αναγνώρισης Λόγου καθώς το 2007 ξεπέρασε άλλες τεχνικές και το 2015 η Google ξεκίνησε να την χρησιμοποιεί σε ένα πρόγραμμα αναγνώρισης λόγου και είχε επιτυχία 49%. [26]

2.1.4.8 Τελευταία εικοσαετία.

Το 2006 ο Geoffrey Hinton σε μια έρευνα [27] του έδειξε πως γίνεται η εκπαίδευση ενός Βαθέως Νευρωνικού Δικτύου (Deep Neural Network), το οποίο ήταν ικανό να

αναγνωρίσει ψηφία χειρόγραφα με ακρίβεια πάνω από 98% που για την εποχή θεωρούνταν κάτι εξωπραγματικό καθώς δεν ήταν πιστευτό πως είναι δυνατόν να εκπαιδευτεί ένα Βαθύ Νευρωνικό Δίκτυο. Η τεχνική αυτή ονομάστηκε “Βαθιά Μάθηση” (Deep Learning). Η έρευνα αυτή απασχόλησε πολύ την επιστημονική κοινότητα και μετέπειτα έρευνες έδειξαν πως η Βαθιά Μάθηση ήταν ικανή να κάνει πράγματα τα οποία καμιά άλλη τεχνική της Μηχανικής Μάθησης δεν ήταν ικανή έως τότε να καταφέρει.

Το 2006 σε ένα πρόγραμμα του Εθνικού Ινστιτούτου και Προτύπων και Τεχνολογίας με όνομα “The Face Recognition Grand Challenge” [28] αξιολόγησαν τους δημοφιλής αλγόριθμους αναγνώρισης προσώπου της εποχής, δοκιμάστηκαν φωτογραφίες της ίριδας του ματιού, τρισδιάστατες σαρώσεις προσώπου (3d scans) και εικόνες υψηλής ανάλυσης. Τα αποτελέσματα έδειξαν πως οι αλγόριθμοι της τότε εποχής ήταν 10 φορές πιο ακριβείς από τους αλγόριθμους αναγνώρισης προσώπου του 2002 και 100 φορές πιο ακριβείς από αλγόριθμους του 1998. Άξιο αναφοράς είναι πως κάποιοι από τους αλγόριθμους κατάφεραν να αναγνωρίσουν πρόσωπα καλύτερα από ανθρώπους και κάποιοι μάλιστα ήταν ικανοί να αναγνωρίσουν ακόμα και πρόσωπα από διδύμους ανθρώπους.

Το 2012, το εργαστήριο X Lab της Google δημιούργησε έναν αλγόριθμο Μηχανικής Μάθησης ο οποίος μπορούσε αυτόνομα να περιηγηθεί στο διαδίκτυο και να βρει βίντεο που περιέχουν γάτες. [29]

Άξιο αναφοράς επίσης είναι πως το 2014 η πρώην Facebook (τώρα META) δημιούργησε το DeepFace έναν αλγόριθμο ικανό να αναγνωρίσει άτομα σε φωτογραφίες με ίδια ακρίβεια με εκείνη των ανθρώπων. [30]

Πλέον, η Μηχανική Μάθηση έχει συνεισφέρει στην ανάπτυξη της τεχνολογίας με ποικίλους τρόπους και έχει γίνει αναπόσπαστο κομμάτι της. Καινοτομίες όπως τα αυτοκίνητα με λειτουργίες αυτόνομης οδήγησης, η ανίχνευση απάτης σε τραπεζικά συστήματα καθώς και σε συστήματα ηλεκτρονικού εμπορίου, οι προτάσεις εξατομικευμένων προϊόντων, οι προτάσεις εξατομικευμένων ταινιών, οι εφαρμογές της στην Βίο-Ιατρική τεχνολογία, στην Ιατρική με πρόσφατα επιτεύγματα στην βοήθεια της μάχης με τον SARS-CoV-2 καθώς και σε πολλούς διαφορετικούς κλάδους, έχουν κάνει την καθημερινότητα των ανθρώπων ευκολότερη και κατά πολύ ασφαλέστερη. [31] [32] [33] [34] [35] [36] [37] [38]

2.2 Το πεδίο της Μηχανικής Μάθησης

Στο παρόν κεφάλαιο παρουσιάζεται και αναλύεται το πεδίο της Μηχανικής Μάθησης.

2.2.1.1 Βασικά στοιχεία της Μηχανικής Μάθησης

Στο παρόν υποκεφάλαιο παρουσιάζονται και αναλύονται βασικά στοιχεία της μηχανικής μάθησης.

2.2.1.2 Τα δεδομένα και το σετ δεδομένων

Ένας εύκολος τρόπος επεξήγησης είναι μέσω ενός μέσου το οποίο χρησιμοποιείται από τους περισσότερους ανθρώπους. Αυτό είναι το email, στο οποίο υπάρχει ένας φάκελος που λέγεται SPAM ή στα ελληνικά ανεπιθύμητη αλληλογραφία. Τα email τα οποία καταλήγουν σε αυτό τον φάκελο έχει αναλάβει να τα αρχειοθετήσει εκεί ένας αλγόριθμος που χρησιμοποιεί τη μέθοδο της Μηχανική Μάθηση. Αυτό γίνεται καθώς ο αλγόριθμος μαθαίνει από δεδομένα. Τα δεδομένα αυτά προέρχονται από ένα σετ δεδομένων το οποίο ονομάζεται “σετ εκπαίδευσης” (training set). Κάθε παράδειγμα εκπαίδευσης ονομάζεται “στιγμιότυπο της εκπαίδευσης”. [39]

Τα δεδομένα είναι παρατηρήσεις ή μετρήσεις οι οποίες αντιπροσωπεύονται ως κείμενο, ως αριθμοί ή ως πολυμέσα. [40]

Ένα σετ δεδομένων είναι μια δομημένη συλλογή από δεδομένα που σχετίζεται με ένα μοναδικό σύνολο εργασιών. [40]

2.2.1.3 Κατηγορίες Μάθησης

Στην Μηχανική Μάθηση οι αλγόριθμοι μπορούν να ταξινομηθούν ανάλογα με την επίβλεψη που κάνουν στην εκπαίδευση. Υπάρχουν 4 βασικές κατηγορίες: Η μάθηση με επίβλεψη (supervised learning), η μάθηση χωρίς επίβλεψη (unsupervised learning), η μάθηση με μερική επίβλεψη (semi-supervised learning) και η μάθηση με ενίσχυση (reinforcement learning). [39]

2.2.1.3.1 Μάθηση με επίβλεψη

Στην μάθηση με επίβλεψη, τα δεδομένα τα οποία χρησιμοποιούνται για να τροφοδοτήσουν τον αλγόριθμο, εμπεριέχουν τις επιθυμητές λύσεις οι οποίες καλούνται ετικέτες (labels). Ονομάζεται έτσι, διότι η διαδικασία εκμάθησης του αλγόριθμου και η εκπαίδευση του με το σετ δεδομένων θυμίζει έναν καθηγητή ο οποίος επιβλέπει την διαδικασία εκμάθησης.

Ένα κλασικό παράδειγμα στο οποίο χρησιμοποιείται η μάθηση με επίβλεψη είναι η ταξινόμηση (classification). Για την μάθηση ενός μοντέλου Μηχανικής Μάθησης για την ταξινόμηση ενός email ως ανεπιθύμητο ή όχι θα χρειαστεί να χρησιμοποιηθεί πάνω του ένας αλγόριθμος ταξινόμησης.

Ένα άλλο παράδειγμα είναι η πρόβλεψη μίας τιμής στόχου, όπως είναι η τιμή ενός ακινήτου δεδομένου ενός σετ χαρακτηριστικών (περιοχή, μέγεθος σε τ.μ., ποσότητα δωματίων κ.α.) τα οποία ονομάζονται προβλεπόμενα (predictors). Αυτή η διαδικασία ονομάζεται παλινδρόμηση (regression).

Κάποιοι αλγόριθμοι ταξινόμησης μπορούν να χρησιμοποιηθούν και για παλινδρόμηση και το αντίθετο.

Κάποιοι από τους πιο σημαντικούς αλγόριθμους με επίβλεψη ονομάζονται παρακάτω:

- K-Κοντινότεροι γείτονες
- Γραμμική Παλινδρόμηση
- Λογιστική Παλινδρόμηση
- Support Vector Machines
- Δέντρα Απόφασης και Τυχαία Δάση
- Νευρωνικά Δίκτυα

2.2.1.3.2 Μάθηση χωρίς επίβλεψη

Στην μάθηση χωρίς επίβλεψη τα δεδομένα εκπαίδευσης δεν έχουν ετικέτα και το μοντέλο προσπαθεί να μάθει χωρίς κάποιον δάσκαλο. Ο στόχος ποικίλει και μπορεί να είναι η ομαδοποίηση των δεδομένων, η εύρεση της κατανομής των δεδομένων στον χώρο η οποία είναι γνωστή και ως εκτίμηση της πυκνότητας, ή η μείωση της διάστασης στο σετ δεδομένων.

Ας υποθέσουμε πως κάποιος έχει μια ιστοσελίδα και κρατάει δεδομένα για τους επισκέπτες. Ας υποθέσουμε επίσης ότι θέλει να χρησιμοποιήσει τα δεδομένα που έχει για να βρει ομάδες από παρόμοιους επισκέπτες. Κατά την διαδικασία της μάθησης ο κάτοχος της ιστοσελίδας δεν έχει δώσει δεδομένα στον αλγόριθμο σχετικά με την ομάδα που ανήκει ο κάθε επισκέπτης και ο αλγόριθμος μαθαίνει από μόνος του να τους ομαδοποιήσει. [39]

Κάποιοι από τους πιο σημαντικούς αλγόριθμους χωρίς επίβλεψη ονομάζονται παρακάτω:

Αλγόριθμοι ομαδοποίησης:

- K-Means
- Hierarchical Cluster Analysis (HCA)
- Expectation Maximization

Αλγόριθμοι οπτικοποίησης και μείωσης διάστασης:

- Principal Component Analysis
- Kernel PCA
- Locally-Linear Embedding (LLE)
- t-distributed Stochastic Neighbor Embedding (t-SNE)

2.2.1.3.3 Μάθηση με μερική επίβλεψη

Σε αυτή την κατηγορία οι αλγόριθμοι μπορούν να χρησιμοποιήσουν δεδομένα τα οποία δεν έχουν σε όλες τις κατηγορίες τους ετικέτες, αποτελούνται κατά ένα μεγάλο ποσοστό από δεδομένα χωρίς ετικέτες και ένα μικρό ποσοστό από δεδομένα με ετικέτες. Οι περισσότεροι αλγόριθμοι με μερική επίβλεψη, αποτελούνται από έναν συνδυασμό αλγορίθμων μάθησης με επίβλεψης και αλγορίθμων μάθησης χωρίς επίβλεψη. [39]

2.2.1.3.4 Μάθηση με επιβράβευση

Μάθηση με ενίσχυση ονομάζεται η κατηγορία αλγορίθμων της μηχανικής μάθησης η οποία είναι εμπνευσμένη από την συμπεριφορική ψυχολογία. Ο τρόπος με τον οποίο λειτουργεί θυμίζει ένα παιδί το οποίο μαθαίνει κάτι καινούργιο. Ένας πράκτορας (agent) καλείται να αλληλοεπιδράσει με ένα περιβάλλον και όταν πάρει μια σωστή απόφαση (π.χ. να κάνει μια σωστή κίνηση στο σκάκι) δέχεται μια επιβράβευση, αλλά αν η απόφαση που πήρε είναι λάθος, τότε δέχεται μια ποινή. Ο σκοπός του πράκτορα είναι να μεγιστοποιήσει τον αριθμό των επιβραβεύσεων του και έτσι να μάθει να επιτυγχάνει (π.χ. να νικάει στο σκάκι). Στην μάθηση με ενίσχυση ο αλγόριθμος μαθαίνει αυτόνομα μέσω αυτής της διαδικασίας χωρίς την παρέμβαση από κάποιον προγραμματιστή. Πράκτορας στην προκειμένη περίπτωση ονομάζεται ο αλγόριθμος ο οποίος αλληλοεπιδρά με το περιβάλλον του αυτόνομα με σκοπό να πετύχει έναν στόχο, που στην παρούσα φάση είναι η μάθηση. [39]

2.2.1.3.5 Μαζική μάθηση και Μάθηση με σύνδεση

Παρακάτω αναλύεται η Μαζική μάθηση και η Μάθηση με σύνδεση.

2.2.1.3.5.1 Μαζική μάθησης

Στην Μαζική Μάθηση (Batch Learning), το σύστημα αδυνατεί να μάθει σταδιακά και πρέπει για να εκπαιδευτεί ώστε να χρησιμοποιήσει όλα τα δεδομένα από ένα σετ δεδομένων. Αυτή η διαδικασία τις περισσότερες φορές είναι εξαιρετικά χρονοβόρα και απαιτεί πολλούς υπολογιστικούς πόρους, για αυτό τον λόγο και γίνεται εκτός σύνδεσης. Μετά την εκπαίδευση του συστήματος χρησιμοποιείται βάση αυτά που έχει μάθει και δεν εκπαιδεύεται περαιτέρω.

Σε ένα σύστημα Μαζικής μάθησης όταν πρέπει να παρουσιαστούν νέα δεδομένα, το σύστημα δεν εκπαιδεύεται μόνο από τα νέα δεδομένα, οπότε πρέπει να εκπαιδευτεί από την αρχή και πάλι με όλα τα δεδομένα, το οποίο, μπορεί πάρει αρκετό χρόνο. Με την πάροδο των χρόνων η διαδικασία της μάθησης και γενικά της χρήσης του συστήματος της Μηχανικής Μάθησης έχει εξελιχθεί και είναι αυτοματοποιημένη. [39]

2.2.1.3.5.2 Μάθηση με σύνδεση

Σε ένα σύστημα που χρησιμοποιεί Μάθηση με Σύνδεση (Online Learning), το σύστημα εκπαιδεύεται σταδιακά τροφοδοτώντας τον αλγόριθμο με στιγμιότυπα δεδομένων. Η τροφοδοσία των δεδομένων γίνεται είτε διαδοχικά, είτε μέσω μικρών ομάδων οι οποίες ονομάζονται mini-batches. Επίσης για να εκπαιδευτεί ένα τέτοιο σύστημα δεν χρειάζεται πολλούς υπολογιστικούς πόρους. Με αυτή την διαδικασία η μάθηση γίνεται με γρήγορο τρόπο και εάν παρουσιαστούν νέα δεδομένα στο σύστημα τότε μαθαίνει γρήγορα από αυτά, καθώς μπορεί να εκπαιδεύεται για όσο διάστημα χρησιμοποιείται. [39]

2.2.1.3.6 Μάθηση με Στιγμιότυπα και Μάθηση με Μοντέλα

Ένας άλλος τρόπος κατάταξης των συστημάτων Μηχανικής Μάθησης είναι: με ποιον τρόπο είναι ικανά να γενικεύσουν τις προβλέψεις τους. Έστω ότι έχει δοθεί ένας αριθμός από δεδομένα εκπαίδευσης: το σύστημα πρέπει αν είναι ικανό να γενικεύσει την λειτουργία του και σε δεδομένα που δεν έχει δει στο παρελθόν.

Υπάρχουν δύο γνωστές προσεγγίσεις στην γενίκευση: Η Μάθηση από στιγμιότυπα και η μάθηση με Μοντέλα. [39]

2.2.1.3.6.1 Μάθηση από Στιγμιότυπα

Στην Μάθηση από Στιγμιότυπα (Instance-based learning) το σύστημα μαθαίνει από τα δεδομένα και στην συνέχεια όταν έρθουν νέα δεδομένα τότε γενικεύει τα δεδομένα από τις είδη υπάρχουσες γνώσεις χρησιμοποιώντας μία μετρική ομοιότητας. [39]

2.2.1.3.6.2 Μάθηση με Μοντέλα

Ένας διαφορετικός τρόπος είναι από ένα σύνολο δεδομένων να φτιαχτεί ένα μοντέλο και να χρησιμοποιηθεί αυτό το μοντέλο με σκοπό την γενίκευση. Αυτή η διαδικασία ονομάζεται μάθηση με Μοντέλα (Model-Based Learning). [39]

2.2.2 Βασικές προκλήσεις της Μηχανικής Μάθησης

Μια από τις σημαντικότερες εργασίες της Μηχανικής Μάθησης είναι η επιλογή ενός αλγορίθμου εκμάθησης και η εκπαίδευση του με δεδομένα. Δυο πράγματα μπορούν να πάνε λάθος τα οποία είναι: [39]

1. Επιλογή λάθος αλγορίθμου
2. Κακή ποιότητα δεδομένων

2.2.2.1 Μη ικανοποιητική ποσότητα δεδομένων

Για να εκπαιδευτεί ένας αλγόριθμος Μηχανική Μάθησης σωστά τότε χρειάζεται ένας μεγάλος αριθμός δεδομένων ακόμα και για πιο “εύκολα” προβλήματα. Όσο όμως αυξάνεται η δυσκολία, τόσο αυξάνεται και ο αριθμός δεδομένων που χρειάζεται ο αλγόριθμος για να μάθει από αυτά. Σε προβλήματα όπως η αναγνώριση ήχου και εικόνας μπορούν χρειαστούν και εκατομμύρια δεδομένα.

Οπότε μια μη ικανοποιητική ποσότητα δεδομένων μπορεί να φέρει άσχημα αποτελέσματα κατά την εκπαίδευση του αλγορίθμου. [39]

2.2.2.2 Μη αντιπροσωπευτικά δεδομένα εκπαίδευσης

Για να καταφέρει ένα μοντέλο να γενικεύσει καλά όταν του παρουσιαστούν νέα δεδομένα, θα πρέπει τα δεδομένα με τα οποία έγινε η εκπαίδευση να είναι αντιπροσωπευτικά και προς τα μελλοντικά δεδομένα τα οποία δεν έχουν παρουσιαστεί στον αλγόριθμο.

Εάν γίνει χρήση ενός μη αντιπροσωπευτικού σετ δεδομένων εκπαίδευσης, τότε μετά την εκπαίδευση το μοντέλο θα είναι ανίκανο να κάνει σωστές προβλέψεις. Εν κατακλείδι είναι σημαντικό να χρησιμοποιηθεί ένα σετ δεδομένων εκπαίδευσης το οποίο θα είναι αντιπροσωπευτικό και ικανό να γενικεύει. [39]

2.2.2.3 Δεδομένα κακής ποιότητας

Εάν τα δεδομένα τα οποία χρησιμοποιήθηκαν για την εκπαίδευση ενός συστήματος περιέχουν λάθη, ανακρίβειες ή θόρυβο (λόγω εσφαλμένων τιμών από αισθητήρες, λόγω λανθασμένων βημάτων κατά την δημιουργία ενός σετ δεδομένων κ.τ.λ.) τότε τα αποτελέσματα του αλγορίθμου δεν θα είναι ικανοποιητικά και κάποιες φορές ίσως οδηγήσουν σε λάθος συμπεράσματα. Οπότε πριν ξεκινήσει η διαδικασία της εκπαίδευσης τα δεδομένα θα πρέπει να ελέγχονται και να “καθαρίζονται” με τέτοιο τρόπο ώστε να εξαχθούν σωστά αποτελέσματα από τον αλγόριθμο. [39]

2.2.2.4 Μη σχετικά χαρακτηριστικά

Εάν τα χαρακτηριστικά τα οποία χρησιμοποιεί το σετ εκπαίδευσης δεν είναι σωστά επιλεγμένα για την καλύτερη δυνατή εκπαίδευση τότε όπως είναι λογικό τα αποτελέσματα της εκπαίδευσης δεν θα είναι καλά. Η διαδικασία κατά την οποία επιλέγονται τα καλύτερα χαρακτηριστικά ονομάζεται “Feature Engineering” και αποτελείται από τα παρακάτω βήματα:

- Επιλογή των χαρακτηριστικών: Δηλαδή, η επιλογή των πιο χρήσιμων χαρακτηριστικών από όλα τα χαρακτηριστικά στο σετ δεδομένων.
- Παραγωγή χαρακτηριστικών: Συνδυασμός υπαρχόντων χαρακτηριστικών για την δημιουργία ενός νέου πιο χρήσιμου χαρακτηριστικού.
- Δημιουργία νέων χαρακτηριστικών αφού έχουν συλλεχθεί περισσότερα δεδομένα. [39]

2.2.2.5 Overfitting και Underfitting

Όταν ένας αλγόριθμος είναι επιτυχής στις προβλέψεις για τα δεδομένα εκπαίδευσης αλλά αποτυγχάνει στην ικανότητα γενίκευσής του, τότε αυτό ονομάζεται Overfitting. Περίπλοκα μοντέλα όπως Βαθιά Νευρωνικά Δίκτυα, μπορούν να ανιχνεύσουν ανεπαίσθητα μοτίβα στα δεδομένα, αλλά εάν τα δεδομένα εκπαίδευσης περιέχουν θόρυβο τότε και το Νευρωνικό Δίκτυο θα ανιχνεύσει λανθασμένα πρότυπα λόγω αυτού και προφανώς αυτά τα μοτίβα δεν θα είναι ικανά να γενικεύσουν όταν εισαχθούν νέα δεδομένα.

Το underfitting είναι το ακριβώς αντίθετο του overfitting και παρατηρείται να συμβαίνει όταν το μοντέλο είναι πολύ απλό για να μάθει την υποκείμενη δομή των δεδομένων. [39]

2.2.2.6 Δοκιμή και επικύρωση των αποτελεσμάτων

Για την διαπίστωση σωστής γενίκευσης ενός μοντέλου σε νέα δεδομένα, πρέπει να δοκιμάζονται νέα δεδομένα και να ελέγχεται η ικανότητα γενίκευσης του μοντέλου σε αυτά.

Ένας τρόπος να γίνει το παραπάνω είναι να χρησιμοποιηθεί το μοντέλο και να καταγραφεί η αποτελεσματικότητά του. Αυτή η τεχνική είναι αποδοτική εάν το μοντέλο δεν λειτουργεί λάθος.

Μια καλύτερη επιλογή είναι ο διαχωρισμός των δεδομένων σε δυο σετ: το σετ εκπαίδευσης (training set) και το σετ δοκιμών (test set). Για την εκπαίδευση, το μοντέλο χρησιμοποιεί το τεστ εκπαίδευσης ενώ για τον έλεγχο των αποτελεσμάτων χρησιμοποιείται το τεστ δοκιμών. Το ποσοστό σφάλματος των δεδομένων που δεν έχει έχουν το μοντέλο ονομάζεται σφάλμα γενίκευσης και προέρχεται από την αξιολόγηση του μοντέλου με το σετ εκπαίδευσης. Αν το μοντέλο επιτύχει με το σετ δεδομένων αλλά το σφάλμα γενίκευσης είναι υψηλό, τότε το μοντέλο κάνει overfitting στο σετ δεδομένων.

Μια γνωστή τεχνική διαχωρισμού των δεδομένων είναι να χρησιμοποιείται το 80% αυτών για το σετ εκπαίδευσης και το 20% για το σετ δοκιμών. [39]

2.2.2.7 K-Fold Cross-Validation

Μια άλλη τεχνική διαχωρισμού των δεδομένων είναι ο αλγόριθμος K-fold Cross Validation η οποία αναλύεται παρακάτω:

Ο αλγόριθμος K-fold Cross-Validation είναι μια διαδικασία δειγματοληψίας που χρησιμοποιείται για την αξιολόγηση μοντέλων μηχανικής μάθησης (βλ. Εικόνα 8) [41]. Ο αλγόριθμος έχει μια μοναδική παράμετρο η οποία ονομάζεται k. Η παράμετρος αυτή αναφέρεται στον αριθμό των ομάδων που θα χωριστεί το σετ δεδομένων.

Ο αλγόριθμος αυτός χρησιμοποιείται ως επί το πλείστον σε προβλήματα μηχανικής μάθησης για να εκτιμήσει την ικανότητα γενίκευσης των αλγόριθμων. Ουσιαστικά χρησιμοποιεί ένα περιορισμένο δείγμα για να εκτιμήσει την απόδοση του μοντέλου όταν χρησιμοποιείται για να κάνει πρόβλεψη για δεδομένα τα οποία δεν χρησιμοποιούνται κατά την εκπαίδευση του μοντέλου. Ο αλγόριθμος είναι της ακόλουθης μορφής:

Βήμα 1: Ανακατεύει το σετ δεδομένων.

Βήμα 2: Χωρίζει το σετ δεδομένων σε k ομάδες

Βήμα 3: Για κάθε μοναδική ομάδα δεδομένων:

1. Χρησιμοποιεί την ομάδα για να κάνει δοκιμή τον αλγόριθμο (test set).
2. Χρησιμοποιεί τις υπόλοιπες ομάδες για να εκπαιδεύσει τον αλγόριθμο (training test).
3. Τοποθετεί ένα μοντέλο στο training test και το αξιολογεί στο test set.
4. Διατηρεί ένα είδος βαθμολογίας (evaluation score) για το πόσο καλή είναι κάθε ομάδα.

Βήμα 4: Συνοψίζει την ικανότητα του μοντέλου χρησιμοποιώντας το evaluation score του μοντέλου . [42]

Iteration 1	Test	Train	Train	Train	Train
Iteration 2	Train	Test	Train	Train	Train
Iteration 3	Train	Train	Test	Train	Train
Iteration 4	Train	Train	Train	Test	Train
Iteration 5	Train	Train	Train	Train	Test

Εικόνα 8: Για $k=5$ ο αλγόριθμος χωρίζει το σετ δεδομένων σε πέντε ομάδες και κάνει πέντε επαναλήψεις επιλέγοντας κάθε φορά διαφορετικό training test και test set

2.2.2.8 Πίνακας Σύγχυσης

Ο πίνακας σύγχυσης δείχνει τι ποσοστό έχει ταξινομηθεί με επιτυχία σε κάθε κατηγορία και τι ποσοστό έχει ταξινομηθεί εσφαλμένα.

		True Class	
		Positive	Negative
Predicted Class	Positive	TP	FP
	Negative	FN	TN

Εικόνα 9: Παράδειγμα πίνακα σύγχυσης

Από την Εικόνα 9 [43] φαίνεται πως υπάρχουν δύο κλάσεις: η Positive και η Negative.

Οι μετρικές ενός πίνακα σύγχυσης είναι οι παρακάτω:

True Positive (TP): Αναφέρεται στις προβλέψεις τις οποίες ο ταξινομητής πρόβλεψε σωστά την κατηγορία (στην προκειμένη περίπτωση ταξινομήσε σωστά στην κατηγορία Positive τις προβλέψεις του).

True Negative (TN): Αναφέρεται στις προβλέψεις τις οποίες ο ταξινομητής πρόβλεψε σωστά την κατηγορία (στην προκειμένη περίπτωση ταξινομήσε σωστά στην κατηγορία Negative τις προβλέψεις του).

False Positive (FP): Αναφέρεται στις προβλέψεις τις οποίες ο ταξινομητής πρόβλεψε λάθος την κατηγορία (στην προκειμένη περίπτωση ταξινομήσε λάθος στην κατηγορία Positive τις προβλέψεις του, ενώ κανονικά θα έπρεπε να έχει ταξινομήσει τις προβλέψεις στην κατηγορία Negative).

False Negative (FP): Αναφέρεται στις προβλέψεις τις οποίες ο ταξινομητής πρόβλεψε λάθος την κατηγορία (στην προκειμένη περίπτωση ταξινομήσε λάθος στην κατηγορία Negative τις προβλέψεις του, ενώ κανονικά θα έπρεπε να έχει ταξινομήσει τις προβλέψεις στην κατηγορία Positive). [44]

2.2.2.9 Μετρικές

Ο πίνακας σύγχυσης είναι ένα πολύ καλό κριτήριο αξιολόγησης για ένα μοντέλο Μηχανικής Μάθησης και μέσω αυτού μπορούν να εξαχθούν πολύ χρήσιμες μετρικές απόδοσης όπως οι παρακάτω:

Ακρίβεια (Accuracy): όπως δηλώνει και το όνομα της, αυτή η μετρική δίνει την ακρίβεια του μοντέλου, δηλαδή τον συνολικό αριθμό των δειγμάτων που ταξινομήθηκαν σωστά. Υπολογίζεται από τον παρακάτω τύπο:

$$Accuracy = \frac{(TP + TN)}{(TP + FP + TN + FN)}$$

Ποσοστό εσφαλμένης ταξινόμησης: δείχνει την εσφαλμένος ταξινομημένα πρότυπα. Υπολογίζεται από τον παρακάτω τύπο:

$$1 - Accuracy$$

Precision: δείχνει πόσα από τα πρότυπα που ανήκαν σε μια κατηγορία ταξινομήθηκαν σωστά σε αυτή την κατηγορία. Υπολογίζεται από τον παρακάτω τύπο:

$$Precision = \frac{TP}{(TP + FP)}$$

Sensitivity ή Recall: δείχνει πόσα από τα θετικά πρότυπα ταξινομήθηκαν σωστά ως θετικά (Positive), λέγεται αλλιώς και True Positive Rate (TPR), πιθανότητα ανίχνευσης και Recall. Υπολογίζεται από τον παρακάτω τύπο:

$$Sensitivity = \frac{TP}{(TP + FN)}$$

Specificity: δείχνει πόσα από τα αρνητικά πρότυπα ταξινομήθηκαν σωστά ως αρνητικά (Negative), λέγεται αλλιώς και True Negative Rate (TRP). Υπολογίζεται από τον παρακάτω τύπο:

$$Specificity = \frac{TN}{(TN + FP)}$$

F1-score: είναι ένας συνδυασμός από το Accuracy και το sensitivity σε μια μετρική. Αυτή η μετρική δείχνει πως υπάρχει μικρό ποσοστό σε εσφαλμένα ταξινομημένα πρότυπα, όσο πιο κοντά βρίσκεται στο 1 τόσο καλύτερη είναι η ταξινόμηση. [45] [46] [47]

$$F1 - score = \frac{2 * (precision * recall)}{(precision + recall)}$$

ROC curve (receiver operating characteristic curve): Είναι ένας γράφος ο οποίος δείχνει την απόδοση ενός μοντέλου ταξινόμησης σε όλα τα κατώφλια ταξινόμησης. Αυτή η καμπύλη είναι μια γραφική παράσταση του **recall** και του **FPR (False Positive Rate)**.

$$FPR = \frac{FP}{(FP + TN)}$$

AUC (area under roc curve): Μετρά ολόκληρη την δισδιάστατη περιοχή κάτω από την ROC curve. Παρέχει ένα συνολικό μέτρο απόδοσης σε όλα τα πιθανά κατώφλια ταξινόμησης. Η μετρική AUC λαμβάνει τιμές από το 0 έως το 1, ένα μοντέλο του οποίου οι προβλέψεις είναι 100% σωστές έχει μια τιμή AUC 1. Η AUC είναι επιθυμητή για τους παρακάτω λόγους:

- Είναι αμετάβλητη ως προς την κλίμακα (scale-invariant). Μετρά πόσο καλά κατατάσσονται οι προβλέψεις, αντί να μετρά τις απόλυτες τιμές τους.
- Μετρά την ποιότητα των προβλέψεων του μοντέλου ανεξάρτητα από το κατώφλι ταξινόμησης που επιλέγεται.

3 Εφαρμογή τεχνικών Μηχανικής Μάθησης με σκοπό την βελτίωση της δρομολόγησης

Σε αυτό το κεφάλαιο θα αναλυθούν τεχνικές μηχανικής μάθησης εστιασμένες στην βελτίωση της δρομολόγησης σε ποικίλους τύπους δικτύων.

3.1 Βελτίωση της απόδοσης της δρομολόγησης σε δίκτυα MANET

Καθώς η εξέλιξη στον τομέα των τηλεπικοινωνιών είναι μεγάλη και αέναη, έχει επιφέρει ως αποτέλεσμα την εξέλιξη των δικτύων τύπου mobile adhoc (MANET) τα οποία είναι αρκετά χρήσιμα και εφαρμόσιμα σε πολλές διαφορετικές περιστάσεις.

Τα δίκτυα mobile adhoc (MANET) είναι ένας αποκεντρωμένος τύπος ασύρματου δικτύου ο οποίος χρησιμοποιεί τους κόμβους ασύρματων συσκευών για να δημιουργήσει ένα δίκτυο το οποίο δεν απαιτεί καμία προ υπάρχουσα υποδομή, όπως για παράδειγμα δρομολογητές ή access points. Κάθε κόμβος συμβάλει στην δρομολόγηση αποστέλλοντας δεδομένα ο ένας στον άλλο. Η απόφαση σχετικά με το ποιος κόμβος θα στείλει δεδομένα σε ποιον γίνεται δυναμικά βασιζόμενη στον αλγόριθμο δρομολόγησης καθώς και στην συνδεσιμότητα του δικτύου.

Κάθε συσκευή η οποία βρίσκεται στο δίκτυο έχει την ικανότητα να κινηθεί προς οποιαδήποτε κατεύθυνση και αυτό έχει ως αποτέλεσμα την συχνή εναλλαγή των συσκευών στις οποίες γίνεται η μεταφορά δεδομένων. Κάθε κόμβος θα πρέπει να λειτουργεί σαν δρομολογητής, δηλαδή να προωθεί την κίνηση που υπάρχει στο δίκτυο και σε άλλους κόμβους και να μεταφέρει σωστά τα δεδομένα στον προορισμό τους. Λόγω των χαρακτηριστικών τους τα δίκτυα αυτά δημιουργούν προβλήματα στην δρομολόγηση των πακέτων και αυτό έχει ως αποτέλεσμα να κρίνεται απαραίτητος κάθε φορά ο καταλληλότερος αλγόριθμος για να επιτευχθεί η αποφυγή του προβλήματος αυτού.

Λόγω της ιδιαιτερότητας των δικτύων αυτών υπήρξε μεγάλη ανάγκη δημιουργίας μια κατάλληλης μεθοδολογίας δρομολόγησης πακέτων, της οποίας υπήρξε κορεσμός. Για να λυθούν οι προκλήσεις των MANET χρησιμοποιήθηκαν τεχνικές δρομολόγησης πακέτων όπως table driven, on demand, βασισμένες στην τοποθεσία, ιεραρχικές, υβριδικές και multipath. Όλες οι παραπάνω μέθοδοι είναι επικεντρωμένες στη βελτίωση του χρόνου ζωής του δικτύου μειώνοντας την κατανάλωση ενέργειας και μειώνοντας την καθυστέρηση στον χρόνο παράδοσης των πακέτων καθώς χρησιμοποιούν την συντομότερη διαδρομή για την

μετάδοση των πακέτων, αλλά έχουν ένα σοβαρό μειονέκτημα το οποίο είναι η αποτυχία διατήρησης μια συνεχούς σύνδεσης μεταξύ των κόμβων.

Στην έρευνα “PERFORMANCE EVALUATION OF ROUTING ALGORITHMS FOR MANET BASED ON THE MACHINE LEARNING TECHNIQUES” [48] η οποία πραγματοποιήθηκε από την Dr. M. Durairandian, προτείνεται μια μέθοδος η οποία χρησιμοποιώντας μια τεχνική μηχανικής μάθησης εν’ονόματι reinforcement learning η οποία έχει σκοπό την πρόβλεψη της κινητικότητας των κόμβων στο δίκτυο σε σχέση με τους κόμβους προορισμού, τείνει να δώσει μια λύση στα προαναφερθέντα προβλήματα.

Η προτεινόμενη μέθοδος χρησιμοποιεί την τεχνική του reinforcement learning συγκεκριμένα εστιασμένη στην δρομολόγηση των πακέτων από τον αρχικό κόμβο προς τον κόμβο προορισμού. Ο αλγόριθμος επιλέγει τους κόμβους με βάση την καθυστέρηση παράδοσης των πακέτων σε συνδυασμό με τους διαθέσιμους κόμβους και τις επιτυχής παραδόσεις των πακέτων σε κάθε κόμβο. Ο προσδιορισμός των κόμβων γίνεται με βάση την ελάχιστη καθυστέρηση παράδοσης των πακέτων καθώς και την ικανότητα μέγιστης μετάδοσης πακέτων. Οι κόμβοι αυτοί στην συνέχεια τοποθετούνται σε έναν αλγόριθμο ομαδοποίησης k-means. Από τις ομάδες κόμβων που υπάρχουν επιλέγεται η καλύτερη με κριτήριο επιλογής το επόμενο hop. Ο κόμβος ο οποίος έχει την μικρότερη απόσταση από τον προορισμό θα είναι ο κόμβος στον οποίο θα γίνει το επόμενο hop. Παρόλο που ο αλγόριθμος επιτρέπει τον εντοπισμό της συντομότερης διαδρομής, το πρόβλημα είναι πως αν οι κόμβοι μετακινηθούν από την αρχική τους θέση τα αποτελέσματα που θα εξαχθούν θα είναι λανθασμένα. Στην προτεινόμενη μέθοδο η τεχνική χρησιμοποιεί την εκτίμηση της κινητικότητας των κόμβων για την διόρθωση αυτού του προβλήματος.

Λόγω της φύσης του δικτύου οι κόμβοι μπορεί να μεταβάλλονται και αυτό φέρει ως αποτέλεσμα την δημιουργία προβλημάτων στην δρομολόγηση των πακέτων. Για να προβλεφθούν οι τοποθεσίες των κόμβων προτείνεται στην έρευνα η χρήση κάποιων καταστάσεων οι οποίες είναι όπως φαίνονται παρακάτω:

Κατάσταση 1	Καθορίζει εάν το πακέτο μπορεί να μεταδοθεί απευθείας ή χρειάζεται κάποια νέα διαδρομή.
Κατάσταση 2	Ξεκινά την αναζήτηση της νέας διαδρομής.

Κατάσταση 3	Διεξάγει την ανακάλυψη νέας διαδρομής και περιμένει για κάποιο σήμα εισόδου με σκοπό την λήψη αποφάσεων.
Κατάσταση 4	Εκτελεί την δρομολόγηση των πακέτων.
Κατάσταση 5	Συλλέγει πληροφορίες σχετικά με τις απαντήσεις και ενημερώνει τον πίνακα που περιέχει πληροφορίες σχετικά με της δρομολόγηση, πηγαίνει στην κατάσταση 4.
Κατάσταση 6	Λειτουργεί ως κόμβος διεπαφής μεταδίδοντας πακέτα στον κόμβο προορισμό.
Κατάσταση 7	Δέχεται την απάντηση και πραγματοποιεί ενημέρωση τιμών όπου χρειάζεται.
Κατάσταση 8	Καθορίζει πότε θα σταματήσει η κατάσταση επεξεργασίας.
Κατάσταση 9	Συνεχίζει την μετάδοση και μεταβαίνει στην κατάσταση 1 για την επόμενη μετάδοση.

Πίνακας 1. Καταστάσεις για την πρόβλεψη της κινητικότητας των κόμβων.

Όταν ένα πακέτο μεταδίδεται από κάποιον κόμβο στον κόμβο προορισμό παρόλο που οι κόμβοι μπορεί να κινούνται συνεχώς, γίνεται η υπόθεση πως ενεργούν με τις καταστάσεις του παραπάνω πίνακα και πως βρίσκονται σε κάποια κατάσταση κατά την οποία δρουν. Με αυτό τον τρόπο διασφαλίζεται η σταθερότητα του μονοπατιού κατά την διάρκεια της μετάδοσης μειώνοντας τις αποτυχίες σύνδεσης των κόμβων και αυξάνοντας την παραγωγικότητα του δικτύου.

Τα αποτελέσματα τα οποία πάρθηκαν συγκρίθηκαν με τις μεθόδους “the fuzzy shortest path for the adhoc networks” [49] και “the firefly based shortest path” [50] και αποδεικνύεται πως η μέθοδος η οποία χρησιμοποιήθηκε είχε καλύτερη αποτελεσματικότητα στο ποσοστό επιτυχών παραδόσεων πακέτων, στην καθυστέρηση της μετάδοσης των πακέτων και στον περιορισμό της ενεργειακής σπατάλης. Άρα υπήρξε συνολική βελτίωση στον χρόνο ζωής του δικτύου.


3.2 Πρόβλεψη σε πραγματικό χρόνο του τύπου ενός ασύρματου δικτύου και επιλογή του καλύτερου επόμενου βήματος (hop)

Στα ασύρματα δίκτυα πολλοί κόμβοι επικοινωνούν μεταξύ τους με σκοπό την αποστολή και λήψη δεδομένων που ως τελικό σκοπό έχουν την σωστή δρομολόγηση των πακέτων. Είναι σημαντικό να επιλεγούν σωστά οι κόμβοι που θα επαναπροωθήσουν τα πακέτα καθώς είναι σημαντικό να υπάρξει ταχεία και επιτυχής παράδοση των πακέτων. Σε ένα Ασύρματο δίκτυο όμως μπορούν να υπάρχουν πολλοί τύποι δικτύων όπως Bluetooth, DTN, MANET κ.α. Στα δίκτυα τα οποία χρησιμοποιούν τεχνολογία Bluetooth για την επικοινωνία των κόμβων η δρομολόγηση είναι απλή διαδικασία καθώς αρκεί απλά ο κόμβος αποστολής να μεταδώσει τα πακέτα του κατευθείαν στον κόμβο προορισμού, αλλά στα δίκτυα DTN και MANET χρειάζονται ενδιάμεσοι κόμβοι οι οποίοι θα προωθήσουν την πληροφορία έως τον τελικό κόμβο. Παρακάτω θα παρουσιαστεί ο τρόπος λειτουργίας και τα αποτελέσματα ενός αλγορίθμου εν'ονόματι “ORuML (Optimized Routing in wireless networks using Machine Learning)” [51] ο οποίος χρησιμοποιεί Μηχανική Μάθηση με σκοπό την πρόβλεψη του τύπου του δικτύου όπου ο κόμβος αποστολής και προορισμού ανήκουν, και για τα δίκτυα τύπου DTN και MANET την πρόβλεψη του καλύτερου επόμενου hop.

Η τεχνολογία Bluetooth χρησιμοποιείται για ανταλλαγή δεδομένων ασύρματα μεταξύ συσκευών που βρίσκονται σε μικρή απόσταση χρησιμοποιώντας UHF ραδιοκύματα. Εκπέμπει στην συχνότητα των 2.4 GHz και μεταφέρει δεδομένα από 79 κανάλια και υποστηρίζει επικοινωνία των συσκευών από σημείο σε σημείο. [52]

Τα δίκτυα DTN (Delay Tolerant Networks) είναι μια κατηγορία δικτύων η οποία επιδιώκει την επίλυση τεχνικών ζητημάτων σε απομονωμένα καθώς και αποσυνδεδεμένα δίκτυα τα οποία δεν έχουν μια σταθερή σύνδεση από άκρη σε άκρη (end to end connection), υπάρχει μεγάλο ποσοστό σφαλμάτων στην παράδοση των πακέτων, υπάρχει καθυστέρηση παράδοσης των πακέτων για ώρες ακόμα και ημέρες κ.α. Είναι σχεδιασμένα να λειτουργούν αποδοτικά σε πολύ μεγάλες αποστάσεις όπως σε δίκτυα τα οποία υπάρχουν στο διάστημα, σε αγροτικές περιοχές, σε στρατιωτικά συστήματα κ.α. Ο τρόπος με τον οποίο λειτουργεί των DTN είναι: κατά την διαδικασία της δρομολόγησης εάν τα πακέτα δεν προωθηθούν αμέσως στον επόμενο κόμβο λόγω κάποιου προβλήματος, αποθηκεύονται από τον εκάστοτε κόμβο και προωθούνται με την πρώτη ευκαιρία στον επόμενο κόμβο. Αυτή η διαδικασία συνεχίζεται μέχρι τα πακέτα να φτάσουν στον κόμβο προορισμό (π.χ. Ένας αστροναύτης

προσπαθεί να επικοινωνήσει με την βάση της NASA στην Γη, αλλά κατά την διάρκεια μετάδοσης των πακέτων, πυκνά σύννεφα καλύπτουν την ατμόσφαιρα και τα πακέτα δεν μπορούν να μεταδοθούν, ο δορυφόρος που χρησιμοποιεί ως διαμεσολαβητής κρατάει αποθηκευμένα τα πακέτα και κάνει προσπάθειες μετάδοσης μέχρι να παραδοθούν τα πακέτα στην βάση) (βλ. Εικόνα 10) . [53] [54]



Εικόνα 10: Επικοινωνία του αστροναύτη με τον σταθμό στην Γη

Για την δημιουργία του σετ δεδομένων χρησιμοποιούνται στοιχεία όπως η μνήμη RAM, ο επεξεργαστής, η διεύθυνση IP, η διεύθυνση MAC, η χρήση της ενέργειας από την συσκευή την στιγμή που δημιουργούνται το σετ δεδομένων καθώς και ο υπολειπόμενος αποθηκευτικός χώρος της συσκευής. Το σετ δεδομένων περιείχε 114 κόμβους με 6 μοναδικά χαρακτηριστικά ο κάθε ένας. Οι παράμετροι του κάθε κόμβου χρησιμοποιήθηκαν για να βρεθεί ο καλύτερος γειτονικός κόμβος για την δρομολόγηση των πακέτων. Η ταυτότητα (ID) κάθε κόμβου λήφθηκε από την διεύθυνση IP του κάθε κόμβου. Ο καθορισμός του καλύτερου γειτονικού κόμβου έγινε με κριτήριο το ποιος γειτονικός κόμβος κατάφερε να παραδώσει τα πακέτα στον κόμβο προορισμού. Εάν ο κόμβος αποστολής και ο κόμβος προορισμού έχουν ίδια ταυτότητα (ID) τότε και οι δύο κόμβοι είναι μέρος του ίδιου δικτύου.

Το καλύτερο hop επιλέχθηκε με βάση το ποσοστό της μπαταρίας την στιγμή που συλλέχθηκαν τα δεδομένα. Αν η μπαταρία την στιγμή αποστολής ενός μηνύματος είναι σε χαμηλά επίπεδα η πιθανότητα παράδοσης των πακέτων μειώνεται καθώς κατά την διαδικασία προώθησης του πακέτου η μπαταρία μπορεί να εξαντληθεί εντελώς και το

πακέτο να χαθεί ή εάν αν ο κόμβος λήψης δεν έχει επαρκή μνήμη να αποθήκευση το μήνυμα, τότε θα υπάρξει αποτυχία αποστολής των πακέτων.

Ένας άλλος παράγοντας καθορισμού των σημαντικών κόμβων είναι το ποσοστό επιτυχών παραδόσεων πακέτων μεταξύ του κόμβου αποστολής και του κόμβου προορισμού, εάν ένα ζεύγος κόμβου αποστολής - προορισμού έχει μεγαλύτερο αριθμό επιτυχημένων παραδόσεων πακέτων από κάποιο άλλο, τότε αυτό το ζεύγος θεωρείται πιο αξιόπιστο και κατ' επέκταση πιο σημαντικό.

Τα χαρακτηριστικά μπαταρία (BPU) και εσωτερικός χώρος (IS) χρησιμοποιούνται για να ταξινομηθούν οι κόμβοι σε διαφορετικές κλάσεις.

Κλάση δικτύου	Κατάσταση
Κλάση 1	Αξιοποίηση της μπαταρίας $\geq 80\%$ και εσωτερικός χώρος $\geq 60\text{GB}$ Ή Αξιοποίηση της μπαταρίας $\geq 80\%$ και $60\text{GB} > \text{εσωτερικός χώρος} > 20\text{GB}$ Ή $80\% > \text{Αξιοποίηση της μπαταρίας} \geq 10\%$ και εσωτερικός χώρος $\geq 60\text{GB}$ Ή $80\% > \text{Αξιοποίηση της μπαταρίας} > 10\%$ $60\text{GB} > \text{εσωτερικός χώρος} > 20\text{GB}$
Κλάση 2	Αξιοποίηση της μπαταρίας $\geq 80\%$ και εσωτερικός χώρος $\leq 20\text{GB}$ Ή $80\% > \text{Αξιοποίηση της μπαταρίας} > 10\%$ και εσωτερικός χώρος $\leq 20\text{GB}$
Κλάση 3	Αξιοποίηση της μπαταρίας $\leq 10\%$ και εσωτερικός χώρος $\geq 60\text{GB}$ Ή Αξιοποίηση της μπαταρίας $\leq 10\%$ και $60\text{GB} > \text{εσωτερικός χώρος} > 20\text{GB}$
Κλάση 4	Αξιοποίηση της μπαταρίας $< 10\%$ και εσωτερικός χώρος $< 20\text{GB}$

Πίνακας 2. Οι κλάσεις που δημιουργήθηκαν


Για την εκπαίδευση του αλγορίθμου χρησιμοποιήθηκαν τρεις τεχνικές κατηγοριοποίησης: Η Multinomial logistic regression, ο αλγόριθμος Support Vector Machine και οι K-Κοντινότεροι Γείτονες (K-Nearest Neighbor). Ο αλγόριθμος Support Vector Machine αναλύεται σε παρακάτω κεφάλαιο οι υπόλοιποι θα αναλυθούν στην συνέχεια.

Ο Multinomial logistic regression ανήκει στους στατιστικούς αλγορίθμους ταξινόμησης, αυτό σημαίνει πως εφόσον δοθεί στην συνάρτηση ένα σετ από χαρακτηριστικά, το μοντέλο θα εκτελέσει μια σειρά από μαθηματικές πράξεις για να ομαλοποιήσει τις τιμές εισόδου σε έναν πίνακα από τιμές, ο οποίος ακολουθεί μια κατανομή πιθανότητας. Η είσοδος είναι το διάνυσμα X και περιέχει τα χαρακτηριστικά $x_1, x_2, x_3 \dots x_N$. Η έξοδος θα είναι το διάνυσμα Y το οποίο θα περιέχει τις πιθανότητες $y_1, y_2, y_3 \dots y_K$ για τις K τιμές στόχου. Εδώ να προστεθεί ότι $y_1 + y_2 + y_3 \dots + y_K = 1$ καθώς το άθροισμα των πιθανοτήτων όλων των πιθανών γεγονότων είναι πάντα 1 . [55]

Ο αλγόριθμος K κοντινότεροι γείτονες λειτουργεί με υποθέσεις, παραδειγματικά αν υπάρχουν τρία σημεία στον χώρο, A, B και Γ, και το σημείο A στον χώρο είναι κοντά στο B με βάση τα χαρακτηριστικά του και δεν είναι κοντά στο C, τότε είναι πιθανό τα δύο αυτά σημεία να ανήκουν στην ίδια ομάδα και όχι στην ομάδα του C. Οπότε όταν κάτι είναι παρόμοιο με κάτι άλλο τότε είναι πιθανό να είναι στην ίδια ομάδα. (βλ. Εικόνα 11) [56] [57]

Ο αλγόριθμος KNN χρησιμοποιεί την ομοιότητα ή απόσταση μεταξύ των σημείων χρησιμοποιώντας κάποιες μαθηματικές πράξεις. Χρησιμοποιεί διάφορες μετρικές της απόστασης και συγκεκριμένα κάποιες από αυτές είναι η ευκλείδεια απόσταση, η Minwosky, η Chi square και άλλες.

Τα αποτελέσματα δόθηκαν μετά από μία σειρά προσομοιώσεων και εκπαιδεύσεων των αλγορίθμων. Οι μετρικές που χρησιμοποιήθηκαν ήταν η ακρίβεια και η AUC και έδειξαν ότι: Ο αλγόριθμος Multinomial logistic regression λειτούργησε καλύτερα από τους άλλους δύο όσων αφορά την ακρίβειά του η οποία ήταν 98.74% και την AUC η οποία ήταν 93.42%. Ο αλγόριθμος KNN ήταν ο δεύτερος καλύτερος με ακρίβεια 92.98% και AUC 79.20% και ο αλγόριθμος SMV είχε τα χειρότερα αποτελέσματα σε σχέση με τους άλλους δύο με ακρίβεια η οποία ήταν 78,95% και AUC 79.20%.



Εικόνα 11: Τα σημεία τα οποία είναι παρόμοια βρίσκονται κοντά το ένα στο άλλο

3.3 Τεχνικές ταξινόμησης σε Delay Tolerant δίκτυα με σκοπό την βελτίωση της δρομολόγησης

Σε μια έρευνα που διεξάχθηκε με όνομα “Delay Tolerant Network Routing as a Machine Learning Classification Problem” [58] από τους Rachel Dudukovich και Christos Parachristou εξετάστηκε σε ένα δίκτυο DTN η απόδοση αλγορίθμων ταξινόμησης σε ένα σύνολο γειτονικών κόμβων για την πρόβλεψη της πιθανότητας παράδοσης των πακέτων στον προορισμό, με βάση το ιστορικό παράδοσης πακέτων.

Η έρευνα είναι εστιασμένη σε σενάρια DTN δικτύων τα οποία χρησιμοποιούνται σε περιοχή εκτός της Γης ή σε συνθήκες αρκετά απρόβλεπτες και δύσκολες (για παράδειγμα σε βάθη ωκεανών, σε περιοχές καταστροφής κ.α.). Για την πιο εύκολη κατανόηση της χρηστικότητάς τους παρατίθεται ένα παράδειγμα: θα μπορούσε να υπάρχει σε κάποια αποστολή σε κάποιον πλανήτη εκτός της Γης κάποιο σμήνος από drones τα οποία θα συλλέγουν φωτογραφίες, θα έκαναν εξερευνούν περιοχές, θα λαμβάνουν δείγματα πετρωμάτων κ.α. Αυτά τα drones θα μπορούσαν να λειτουργούν ως κόμβοι και να αποστέλλουν τα δεδομένα που έχουν συλλέξει στον προορισμό τους απευθείας ή μέσω

δορυφόρων. Το πρόβλημα που δημιουργείται σε τέτοιες περιπτώσεις το δίκτυο δεν είναι η αστάθεια του δικτύου καθώς και κόμβοι μπορεί να προστίθενται και να αφαιρούνται (ίσως καταστραφεί κάποιο drone, να προστεθεί κάποιο καινούργιο κ.τ.λ.). Για τους παραπάνω λόγους απαραίτητη κρίνεται η εφαρμογή κάποιας τεχνικής δρομολόγησης η οποία θα είναι σε θέση να δρομολογεί τα πακέτα ακόμα και αν κάποιοι κόμβοι δεν είναι ικανοί να τα προωθήσουν. Στην έρευνα παρουσιάζονται τεχνικές οι οποίες χρησιμοποιούν αλγόριθμους ταξινόμησης για την επίλυση των παραπάνω προβλημάτων.

Η επιλογή των αλγορίθμων που δοκιμάστηκαν για την επίλυση προβλημάτων σαν αυτό που περιεγράφηκε στην παραπάνω παράγραφο έγινε καθώς λήφθηκε υπόψιν πως στο πρόβλημα αυτό κόμβοι εισέρχονται στο δίκτυο, αποχωρούν και γενικά ακολουθούν διαφορετικά χρονικά καθεστώτα. Με βάση τα παραπάνω κριτήρια, επιλέχθηκαν για χρήση οι παρακάτω αλγόριθμοι (Naïve Bayes, Δέντρα Αποφάσεων και K-Κοντινότεροι γείτονες).

Ο Naive Bayes είναι ένας απλός πιθανοτικός ταξινόμησης βασισμένος στο θεώρημα του Bayes. Ο αλγόριθμος υποθέτει πως υπάρχει ανεξαρτησία μεταξύ των χαρακτηριστικών.

Για να γίνει η κατηγοριοποίηση κατά Bayes θα πρέπει να υπολογιστεί η πιθανότητα παρατήρησης ενός στιγμιότυπου που ανήκει στην κατηγορία (A) δοθέντος του συνόλου των χαρακτηριστικών (B), αυτό ονομάζεται εκ των υστέρων πιθανότητα $P(B|A)$. Η εκ των υστέρων πιθανότητα μπορεί να αναπαρασταθεί ως εξής.


$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

Ο πρώτος όρος $P(B|A)$ είναι γνωστός ως εξαρτώμενη από την κατηγορία πιθανότητα των χαρακτηριστικών δεδομένης της κατηγορίας (A). Η $P(B|A)$ μετρά της πιθανότητα παρατήρησης του (A) από την κατανομή των στιγμιότυπων που ανήκουν στην κατηγορία (A). Ο δεύτερος όρος ονομάζεται η εκ των προτέρων πιθανότητα $P(A)$. Η $P(A)$ συμβολίζει τις εκ των προτέρων γνώσεις σχετικά με την κατανομή των τιμών. Ο όρος στον παρονομαστή είναι μια σταθερά κανονικοποίησης κατά τον υπολογισμό των εκ των υστέρων πιθανοτήτων. Μέσω του παραπάνω τύπου ο ταξινομητής “εξάγει” συμπεράσματα και δίνει τα αποτελέσματα για την “μαντεψιά” που έκανε σχετικά με την κατηγοριοποίηση των χαρακτηριστικών του σετ δεδομένων. [59]

Οι κατηγοριοποιητές Δένδρου (βλ. Εικόνα 12) [60] αποτελούνται από:

- Τον κόμβο ρίζα ο οποίος βρίσκεται στην αρχή του δένδρου και δεν έχει εισερχόμενες ακμές και έχει από 0 έως πολλές εξερχόμενες ακμές.
- Τους εσωτερικούς κόμβους, οι οποίοι έχουν μια εισερχόμενη ακμή και δύο ή περισσότερες εξερχόμενες.
- Τα φύλλα ή αλλιώς τους τερματικούς κόμβους, καθένας από τους οποίους έχει ακριβώς μια εισερχόμενη και μια εξερχόμενη ακμή. Κάθε φύλλο του δένδρου απόφασης, σχετίζεται με μία έξοδο κάποιας κατηγορίας.

Οι μη τερματικοί κόμβοι (ρίζα, εσωτερικοί κόμβοι) περιέχουν συνθήκες ελέγχου χαρακτηριστικών, οι οποίες συνήθως ορίζονται από κάποιο χαρακτηριστικό. Με κάθε πιθανό αποτέλεσμα της συνθήκης ελέγχου χαρακτηριστικών σχετίζεται ακριβώς ένα παιδί αυτού του κόμβου. Δοθέντος ενός δένδρου απόφασης, η κατηγοριοποίηση γίνεται ως εξής: Ξεκινώντας από τον κόμβο ρίζα, εφαρμόζεται κάποια συνθήκη ελέγχου του χαρακτηριστικού του και ακολουθεί η κατάλληλη διακλάδωση με βάση το αποτέλεσμα του ελέγχου. Αυτό θα οδηγήσει σε έναν άλλο εσωτερικό κόμβο, για τον οποίο θα εφαρμοστεί μία νέα συνθήκη ελέγχου χαρακτηριστικού, είτε σε ένα φύλλο. Η έξοδος της κατηγορίας που σχετίζεται με το φύλλο κόμβο αποδίδεται στην συνέχεια από το στιγμιότυπο ελέγχου, αν δεν υπάρχει κάποια συνέχεια σε κάποιον κόμβο ο αλγόριθμος σταματά. [61]



Εικόνα 12: Δένδρα απόφασης για το πρόβλημα του Play Tennis

Για την αξιολόγηση της απόδοσης των αλγορίθμων χρησιμοποιήθηκαν τέσσερις μετρικές απόδοσης. Οι μετρικές ήταν: η συνάρτηση Hamming Loss, η zero-one loss, η F1 και η Jaccard.

Η Hamming Loss υπολογίζει το κλάσμα των εσφαλμένα ταξινομημένων κατηγοριών. Εάν η τιμή της μετρικής είναι πιο κοντά στο ένα τότε, είναι ένα σημάδι πως η ταξινόμηση έχει γίνει σωστά, ενώ αν είναι κοντά στο μηδέν είναι σημάδι πως δεν έχει γίνει σωστή ταξινόμηση.

Η zero-one loss λειτουργεί σαν την Hamming Loss με την διαφορά ότι αν βρεθεί το παραμικρό σφάλμα στην ταξινόμηση τότε, θεωρεί όλη την πρόβλεψη της ταξινόμησης εσφαλμένη.

Η μετρική Jaccard similarity, είναι το μέγεθος της τομής δύο συνόλων κατηγοριών διαιρούμενος με το μέγεθος της ένωσης των δύο κατηγοριών ετικετών.

Το δέντρο απόφασης είχε καλύτερη απόδοση σε σχέση με τους άλλους δυο αλγόριθμους και απέδωσε καλύτερα και στις 4 μετρικές που χρησιμοποιήθηκαν.

Τα συμπεράσματα είναι πως οι αλγόριθμοι ταξινόμησης Μηχανικής μάθησης μπορούν να προβλέψουν την κίνηση σε ένα δίκτυο και να “αποφασίσουν” ποιοι κόμβοι θα

χρησιμοποιηθούν από το δίκτυο κατά την μεταφορά πακέτων. Τα παραπάνω μπορούν να χρησιμοποιηθούν για να παρθούν αποφάσεις με σκοπό την βελτίωση της δρομολόγησης.

3.4 Πρόβλεψη σε πραγματικό χρόνο τεράστιων ποσοτήτων δεδομένων σε κανάλια για καλύτερη δρομολόγηση πακέτων

Καθώς οι κόμβοι σε ένα δίκτυο πολλαπλασιάζονται και στέλνονται πακέτα από τον έναν κόμβο στον άλλο, έχει παρατηρηθεί ότι σε κάποια κανάλια μετάδοσης υπάρχει ένα πρόβλημα, το οποίο είναι η ασυνήθιστα αυξημένη ροή δεδομένων, η οποία σε μία έρευνα που παρουσιάστηκε το 2001 με όνομα “The War Between Mice and Elephants” [62] ονομάστηκε Elephant flow. Πιο συγκεκριμένα, ένα μεγάλο κομμάτι της κίνησης του δικτύου μεταδίδεται μέσω ενός μικρού αριθμού καναλιών, πράγμα που προκαλεί προβλήματα στο εύρος ζώνης του δικτύου καθώς το υπερφορτώνει με πακέτα, πολλά από τα οποία τείνουν να χρειάζονται αναδρομολόγηση ούτως ώστε να καταφέρουν να φτάσουν στον προορισμό τους. Αυτό έχει ως αποτέλεσμα την καθυστέρηση παράδοσης των πακέτων και την σύγχυση του δικτύου καθώς κάποια κανάλια χρησιμοποιούνται υπερβολικά και άλλα σχεδόν καθόλου. Τα κανάλια τα οποία δεν χρησιμοποιούνται τόσο ονομάζονται mice. Πιο συγκεκριμένα τα Elephant flows μπορεί να στέλνουν αρκετά gigabytes καταλαμβάνοντας ένα κανάλι για μέχρι και ώρες ολόκληρες ενώ υπάρχουν και άλλα κανάλια στο δίκτυο τα οποία θα μπορούσαν να χρησιμοποιηθούν για την αποσυμφόρηση του δικτύου.

Το πρόβλημα αυτό φαίνεται να μπορεί να προβλεφθεί όταν έχει ξεκινήσει σε ένα κανάλι για κάποιο χρονικό διάστημα ένα elephant flow και έχει ήδη υπάρξει συμφόρηση στο δίκτυο, η λύση θα μπορούσε να επέλθει κατευθύνοντας τα πακέτα στα κανάλια του δικτύου στα οποία δεν χρησιμοποιούνται το ίδιο ενεργά, μοιράζοντας τα πακέτα καταφέροντας την τελική αποσυμφόρηση του δικτύου. Αυτή μπορεί να είναι μια λύση αλλά λόγω του γεγονότος ότι υπάρχει η καθυστέρηση στην παράδοση των πακέτων και η συμφόρηση του δικτύου είναι αυξημένη δεν θεωρείται αρκετά αποδοτική.

Σε μία έρευνα [63] που πραγματοποιήθηκε από τους Pascal Poupert, Zhitang Chen, Priyank Jaini, Fred Fung, Hengky Susanto, Yanhui Geng, Li Chen, Kai Chen και Hao Jin στο πανεπιστήμιο του Βατερλώ στον Καναδά προτάθηκε η χρήση τεχνικών εξόρυξης δεδομένων για τον υπολογισμό του μεγέθους κάθε ροής δεδομένων κατά το ξεκίνημα της. Χρησιμοποιώντας εκτιμητές μεγέθους μιας ροής δεδομένων (οι οποίοι λειτουργούν με αλγόριθμους μηχανικής μάθησης), μπορεί να προβλεφθεί από κάποια χαρακτηριστικά (π.χ. το μέγεθος του πακέτου, οι πληροφορίες που βρίσκονται στην επικεφαλίδα κ.τ.λ.) των

πρώτων πακέτων που στέλνονται το μέγεθος κάθε ροής των δεδομένων. Τα μεγέθη τα οποία προβλέφθηκαν στην συνέχεια μπορούν να χρησιμοποιηθούν για την καλύτερη δρομολόγηση των πακέτων στο δίκτυο.

Για την προ-επεξεργασία των δεδομένων δημιουργήθηκαν 7 κατηγορίες οι οποίες είναι οι ακόλουθες: η διεύθυνση πηγής της ip, η διεύθυνση προορισμός της ip, η θύρα πηγής (source port), η θύρα προορισμού της ip, το πρωτόκολλο, το server vs client, και το μέγεθος των τριών πρώτων πακέτων δεδομένων.

Για την εκπαίδευση των μοντέλων χρησιμοποιήθηκαν: Νευρωνικά Δίκτυα, Gaussian processes και Μόντελα μίξης Gauss (Gaussian Mixture Models).

Κατά την χρήση των Νευρωνικών Δικτύων για την εκπαίδευση χρησιμοποιήθηκαν 106 δυαδικοί κόμβοι, δύο κρυμμένα επίπεδα με 60 και 40 κόμβους (υπερβολικής εφραπτομένης) και ένα επίπεδο εξόδου ενός κόμβου. Ως συνάρτηση ενεργοποίησης στην έξοδο χρησιμοποιήθηκε η υπερβολική εφραπτομένη έτσι ώστε το αποτέλεσμα να είναι 1 ή -1. Όταν το αποτέλεσμα της υπερβολικής εφραπτομένης είναι αρνητικό η κίνηση στο δίκτυο κατηγοριοποιείται ως mice ενώ όταν το αποτέλεσμα είναι θετικό τότε η κίνηση στο δίκτυο κατηγοριοποιείται ως elephant.

Η εκπαίδευση με Gaussian Process Regression χρησιμοποιεί ένα μη παραμετρικό Bayesian μοντέλο το οποίο χρησιμοποιήθηκε για τον υπολογισμό κατανομής της ροής του δικτύου βασισμένη στα χαρακτηριστικά εισόδου.

Τέλος χρησιμοποιήθηκε ο αλγόριθμος Online Bayesian Moment Matching, όπου ουσιαστικά χρησιμοποιεί μοντέλα μίξης Gauss για την πρόβλεψη των ροών elephant. Ο αλγόριθμος Online Bayesian Moment Matching είναι ένας διαδραστικός online Bayesian αλγόριθμος εκμάθησης ο οποίος μαθαίνει Μοντέλα Μίξης χρησιμοποιώντας την μέθοδο των στιγμών (method of moments).

Για την εκπαίδευση των μοντέλων χρησιμοποιήθηκαν τρία σετ δεδομένων τα οποία περιείχαν δεδομένα τριών χιλιάδων πακέτων και άνω το καθένα. Το ποσοστό των elephant flows ήταν αρκετά μικρό (12%) σε σχέση με τα mice flows, αυτό φέρει ως αποτέλεσμα κατά την χρήση των μοντέλων ένα μεγάλο ποσοστό των προβλέψεων να είναι mice flows λόγω αυτής της ανισορροπίας των κλάσεων. Το πρόβλημα αυτό λύθηκε καθώς τα εσφαλμένα

ταξινομημένα πρότυπα πολλαπλασιαστήκαν με ένα βάρος που ήταν αντιστρόφως ανάλογο με το ποσοστό τους κατά την διάρκεια της εκπαίδευσης.

Το Νευρωνικό Δίκτυο και η τεχνική online Bayesian Moment Matching έδειξαν να επηρεάζονται περισσότερο από αυτή την ανισοκατανομή των χαρακτηριστικών στις κλάσεις σε σχέση με την διαδικασία του Gauss η οποία ήταν πιο αποτελεσματική σε αυτές τις ανισοκατανομές καθώς διατήρησε την κατανομή της σε όλες τις πιθανές υποθέσεις.

Τα αποτελέσματα του πειράματος ήταν αρκετά ενθαρρυντικά και φάνηκε πως μπορούν να χρησιμοποιηθούν αλγόριθμοι μηχανικής μάθησης με επιτυχία για την εκτίμηση του μεγέθους της ροής δεδομένων σε ένα δίκτυο καθώς και την εκτίμηση των elephant flows χρησιμοποιώντας τα πρώτα πακέτα από κάθε ροή δεδομένων. Η πολιτική δρομολόγησης που προέκυψε μείωσε σημαντικά τα elephant flows ενώ κράτησε τα mice flows σε παρόμοια επίπεδα. Η έρευνα αυτή φάνηκε να είναι ικανοί να λύσει το σημαντικό αυτό πρόβλημα.

3.5 Χρήση μοντέλων μίξης με σκοπό την δρομολόγηση σε Opportunistic IoT δίκτυα

Το Διαδίκτυο των Πραγμάτων (IoT) έχει γνωρίσει τεράστια άνθιση τα τελευταία χρόνια και η χρήση του στην καθημερινότητα των ανθρώπων σε ποικίλες μορφές είναι αναντικατάστατη.

Το Internet of Things είναι ένα δίκτυο το οποίο αποτελείται από συσκευές οι οποίες αποτελούνται από αισθητήρες, λογισμικό, έχουν επεξεργαστική ισχύ κ.α. και έχουν την ικανότητα να επικοινωνούν μεταξύ τους μέσω του διαδικτύου. Κάποιες από αυτές τις συσκευές είναι τα έξυπνα τηλέφωνα, τα έξυπνα ρολόγια, γενικά συσκευές οι οποίες ανήκουν στην κατηγορία «Έξυπνο Σπίτι» (θερμοστάτες, κάμερες, ασφαλείας, έξυπνα ψυγεία, στόρια κ.α.), αυτόνομα αυτοκίνητα, έξυπνες πόλεις, έξυπνα συστήματα ελέγχου την κίνησης σε ένα δίκτυο καθώς και συσκευές στον τομέα της υγείας κ.α. [64]

Το πρόβλημα με αυτό τον τύπο δικτύου είναι πως υπάρχουν διακοπές στις συνδέσεις μεταξύ των κόμβων λόγω έλλειψης διαδικτυακών υποδομών σε περιοχές. Για τον παραπάνω λόγο γίνεται κατανοητό πως η χρήση τους περιορίζεται σε κάποιες γεωγραφικές περιοχές.

Για την αποφυγή των παραπάνω περιορισμών οι ερευνητές έχουν προτείνει μια νέα κατηγορία IoT δικτύου το οποίο ονομάζεται Opportunistic IoT (Opplot). Σε αντίθεση με τα κλασικά δίκτυα IoT τα οποία χρησιμοποιούν μια end to end σύνδεση στις συσκευές τους,

τα δίκτυα Opploot δεν έχουν υποδομές, για να δρομολογηθούν τα πακέτα στις συσκευές του δικτύου, χρησιμοποιούνται επαφές σύνδεσης (Wi-Fi, Bluetooth και άλλα μέσα). Για να την επίτευξη της δρομολόγησης θα πρέπει δυο ή περισσότερες συσκευές στο δίκτυο να βρίσκονται σε κοντινή απόσταση και να συνδεθούν, αν δεν υπάρχουν συσκευές να συνδεθούν λόγω έλλειψης επαφών σύνδεσης τα πακέτα φυλάσσονται μέχρι να βρεθούν επαφές και τότε δρομολογούνται. Τα δίκτυα αυτά είναι ιδανικά για περιοχές οι οποίες είναι ελλειπείς σε κάλυψη και υποδομές.

Λόγω της έλλειψης υποδομών, της έλλειψης γνώσης της τοπολογίας του δικτύου και της έλλειψης αρχιτεκτονικής του δικτύου, τα δίκτυα αυτά παρουσιάζουν προβλήματα στην δρομολόγηση των πακέτων η οποία γίνεται μια αρκετά απαιτητική διαδικασία

Μία λύση σε αυτά τα προβλήματα προτείνεται από τους: V. Vashishth, A. Chhabra and D.K. Sharma στην έρευνα “GMMR: A Gaussian mixture model based unsupervised machine learning approach for optimal routing in opportunistic IoT networks” [65] όπου προτείνεται ένα πρωτόκολλο το οποίο ονομάζεται GMMR, στο οποίο χρησιμοποιούνται Μοντέλα Μίξης Gauss, μια τεχνική Μηχανικής Μάθησης που είναι στην κατηγορία των αλγόριθμων μάθησης χωρίς επίβλεψη.

Η μέθοδος επίλυσης του προβλήματος της δρομολόγησης στα OppIoT δίκτυα φαίνεται πως καταλήγει στην λήψη αποφάσεων σχετικά με την δρομολόγηση των δεδομένων κάθε φορά που οι κόμβοι συναντώνται. Οι αποφάσεις αυτές αφορούν την επιλογή ενός συνόλου γειτονικών κόμβων που θα μεταφέρουν με την σειρά τους το μήνυμα. Αν αναλυθούν οι πληροφορίες του δικτύου καθώς και τα χαρακτηριστικά των κόμβων τότε θα είναι πιο φανερό ποιοι κόμβοι είναι ικανότεροι να μεταφέρουν τα πακέτα. Χρησιμοποιώντας τέτοιες πληροφορίες για το εκάστοτε δίκτυο, αυξάνεται η πιθανότητα παράδοσης των πακέτων μέσω της δρομολόγησης. Το GMMR χρησιμοποιεί τις παραπάνω (και όχι μόνο) πληροφορίες του δικτύου με σκοπό να ομαδοποιήσει τις συσκευές του δικτύου οι οποίες έχουν παρόμοια χαρακτηριστικά. Στην συνέχεια δρομολογεί τα πακέτα στις συσκευές κάθε ομάδας.

Το GMMR υλοποιείται σε δύο φάσεις. Στην πρώτη φάση, η οποία είναι και η φάση της προ επεξεργασίας των δεδομένων, τα δεδομένα τα οποία σχετίζονται με συγκεκριμένα χαρακτηριστικά του δικτύου εξάγονται και αποθηκεύονται. Τα δεδομένα τα οποία χρησιμοποιούνται στο GMMR για την δρομολόγηση των πακέτων είναι: η συχνότητα που

τα πακέτα φτάνουν στον προορισμό, η απόσταση από τον προορισμό, πόσα δεδομένα μπορεί να “κρατήσει” ο κόμβος και ο αριθμός των επιτυχημένων παραδόσεων πακέτων. Στην συνέχεια ο αλγόριθμος εκπαιδεύεται με αυτά τα δεδομένα με την τεχνική με όνομα Expectation Maximization. Στην δεύτερη φάση ο εκπαιδευμένος αλγόριθμος δημιουργεί ομάδες και ομαδοποιεί τις συσκευές, μετά αποστέλλει ένα μήνυμα σε όλες τις συσκευές οι οποίες έχουν παρόμοια γνωρίσματα με την συσκευή προορισμού.

Τα αποτελέσματα που πάρθηκαν συγκρίθηκαν με την απόδοση των KNNR, MLPROPH, PROPHET και HBPR. Τα κριτήρια της απόδοσης ήταν: Ο αριθμός των Hop ανά μέσο όρο, ο οποίος όταν είναι μικρός σε μέγεθος υποδηλώνει μια ταχεία παράδοση του μηνύματος, την γενική αναλογία (overhead ratio) η οποία όταν βρίσκεται σε μικρότερα μεγέθη υποδεικνύει καλύτερη αξιοποίηση του χώρου στο δίκτυο, την πιθανότητα παράδοσης του μηνύματος στον προορισμό, η οποία όσο μεγαλύτερο είναι το μέγεθος της τόσο καλύτερη είναι η αξιοπιστία του πρωτοκόλλου και τέλος ο αριθμός των μη παραδομένων μηνυμάτων του οποίου το μεγαλύτερο μέγεθος υποδεικνύει ένα συμφορημένο δίκτυο. Σε όλα τα παραπάνω κριτήρια το GMMR είχε καλύτερη απόδοση από τα άλλα πρωτόκολλα.


3.6 Βελτίωση της δρομολόγησης με επίκεντρο την ενέργεια σε ασύρματα δίκτυα με χρήση Support Vector Machines

Τα ασύρματα δίκτυα όπως έχει αναφερθεί και παραπάνω είναι πολύ σημαντικά για διαφορετικά σενάρια. Σε αυτό το υποκεφάλαιο θα αναλυθεί μια έρευνα η οποία χρησιμοποιεί μια μέθοδο Μηχανικής Μάθησης με όνομα Support Vector Machines (SMV) και προτείνεται ένας αλγόριθμος δρομολόγησης του οποίου τα αποτελέσματα συγκρίνονται με το κλασικό πρωτόκολλο δρομολόγησης των ασύρματων δικτύων Low Energy Adaptive Clustering Hierarchy (LEACH). [66]

Οι ασύρματοι αισθητήρες συχνά χρησιμοποιούνται σε δυσπρόσιτες περιοχές και σκοπός τους είναι να κάνουν μετρήσεις για πιθανούς σεισμούς, έκτακτα καιρικά φαινόμενα, πλημμύρες, θερμοκρασία κ.α. Λόγω της θέσης τους σε πολλές περιπτώσεις η επαναφόρτιση των πηγών ενέργειας τους είναι ένα απαιτητικό εγχείρημα ή ακόμα και αδύνατο. Η ανάγκη λοιπόν για δρομολόγηση η οποία είναι αποδοτική ως προς την εξοικονόμηση ενέργειας κρίνεται αναγκαία. Σε έρευνες Αλγόριθμοι μηχανικής μάθησης έχουν χρησιμοποιηθεί έναντι των κλασικών αλγορίθμων δρομολόγησης και τα αποτελέσματα τα οποία πάρθηκαν ήταν καλύτερα.

Σε αυτή την έρευνα [67] ο αλγόριθμος που χρησιμοποιείται είναι ομαδοποίησης και ανήκει στο πρωτόκολλο ιεραρχικής δρομολόγησης (Hierarchical routing protocol). Το πρωτόκολλο αυτό χρησιμοποιείται ως επί των πλείστων επειδή είναι ικανό να διαχειρίζεται αποτελεσματικά την ενέργεια σε ένα δίκτυο. Σε ένα ιεραρχικό πρωτόκολλο δρομολόγησης οι κόμβοι αισθητήρες είναι χωρισμένοι σε έναν αριθμό από ομάδες με κάθε ομάδα να έχει μια κεφαλή. Οι αισθητήρες κόμβοι είναι υπεύθυνοι όταν κάνουν μετρήσεις να τις στείλουν στην κεφαλή της εκάστοτε ομάδας. Η κεφαλή με την σειρά της λαμβάνει τα δεδομένα και τα στέλνει στον σταθμό βάσης (base station).

Ο αλγόριθμος Support vector ανήκει στην κατηγορία μάθησης με επίβλεψη, χρησιμοποιείται για να λύσει προβλήματα κυρίως ταξινόμησης καθώς και παλινδρόμησης (βλ. Εικόνα 13) αλλά σε κάποιες περιπτώσεις σαν αυτή της έρευνας χρησιμοποιείται για ομαδοποίηση. Ο αλγόριθμος έχει ως σκοπό να λάβει δεδομένα και να τα χωρίσει δύο ή περισσότερες κατηγορίες με ένα υπερεπίπεδο ιδανικά (βλ. Εικόνα 13) [68]. Το υπερεπίπεδο είναι μια ευθεία η οποία διαχωρίζει δυο ή περισσότερες κατηγορίες μεταξύ τους. Οι κατηγορίες διαχωρίζονται από το υπερεπίπεδο ως εξής: Η απόσταση μεταξύ του υπερεπιπέδου και του κοντινότερου σημείου των δεδομένων ονομάζεται όριο (Margin). Στόχος είναι το υπερεπίπεδο να βρίσκεται σε σημείο τέτοιο ώστε το όριο να έχει όσο υψηλότερη τιμή γίνεται έτσι, διασφαλίζεται η σωστή ταξινόμηση των στοιχείων. Τα σημεία τα οποία βρίσκονται πιο κοντά στο υπερεπίπεδο ονομάζονται support vectors και παίζουν καθοριστικό ρόλο στην τοποθέτηση του υπερεπιπέδου και τον διαχωρισμό των κατηγοριών.



Εικόνα 13: Γραφική απεικόνιση του αλγόριθμου SMV

Ο αλγόριθμος αυτός σε αντίθεση με άλλους αλγόριθμους όπως ο K-Means έχει υψηλή απόδοση και σε σετ δεδομένων με υψηλή διάσταση, είναι αρκετά αποδοτικός όταν τα δεδομένα είναι λιγότερα από τις διαστάσεις, απαιτεί λιγότερη δέσμευση στην RAM κ.α. Αξίζει να σημειωθεί πως παρόλα τα θετικά του, ο αλγόριθμος έχει μειωμένη απόδοση σε περιπτώσεις όπου στο σετ δεδομένων ο αριθμός των χαρακτηριστικών υπερβαίνει τον αριθμό των δεδομένων. [69] [70]

Για την προσομοίωση του πρωτοκόλλου χρησιμοποιήθηκαν 3 είδη ασύρματων δικτύων. Το πρώτο είδος αποτελούταν από ασύρματα δίκτυα μικρά σε μέγεθος (5 ομάδες οι οποίες αποτελούνταν από 5 κόμβους η κάθε μια), το δεύτερο είδος αποτελούταν από ασύρματα δίκτυα μεσαία σε μέγεθος (7 ομάδες οι οποίες αποτελούνταν από 7 κόμβους η κάθε μια) και το τρίτο είδος αποτελούταν από ασύρματα δίκτυα μεγάλα σε μέγεθος (10 ομάδες οι οποίες αποτελούνταν από 10 κόμβους η κάθε μια).

Οι αλγόριθμοι συγκρίθηκαν με βάση την ενέργεια που χρειάστηκαν, την καθυστέρηση παράδοσης των πακέτων, την επιβάρυνση λόγω επεξεργασίας και την επιβάρυνση λόγω χρήσης της μνήμης. Η προσομοίωση έδειξε πως η δρομολόγηση χρησιμοποιώντας τον αλγόριθμο SMV χρησιμοποίησε λιγότερη ενέργεια σε σχέση με το πρωτόκολλο LEACH. Η αναλογία παράδοσης των πακέτων είναι ελάχιστη, η μνήμη που χρησιμοποιήθηκε λιγότερη και η επεξεργαστική ισχύς λιγότερη. Αυτά τα αποτελέσματα δείχνουν πως αν χρησιμοποιηθεί το προτεινόμενο πρωτόκολλο έναντι του LEACH τα αποτελέσματα που θα παρθούν στον τομέα της κατανάλωσης ενέργειας θα είναι πολύ καλύτερα.

3.7 Χρήση τεχνικών Μηχανικής Μάθησης σε δίκτυα Software Defined.

Τα Software-Defined δίκτυα (SDNs) είναι μια προσέγγιση διαχείρισης δικτύων η οποία σε αντίθεση με τις κλασικές μεθόδους διαχείρισης, τα δίκτυα γίνονται προγραμματιζόμενα μέσω λογισμικού χωρίς να περιορίζονται κατασκευαστικά στην απόδοσή τους. Για την λήψη των αποφάσεων υπεύθυνος είναι ένας (ή πολλαπλοί) ελεγκτής (controller) ο οποίος κατασκευάζει την τοπολογία του δικτύου και την ελέγχει. Ο ελεγκτής είναι υπεύθυνος για την διαχείριση των πακέτων, για ενημερώσεις στον εξοπλισμό του δικτύου, για τον τρόπο διαχείρισης του δικτύου ανάλογα με τις απαιτήσεις του κ.α.. Με αυτό τον τρόπο η διαχείριση ολόκληρου του δικτύου γίνεται μέσω ενός μοναδικού σημείου το

οποίο είναι ο ελεγκτής. Λόγω του μοναδικού σημείου ελέγχου όταν χρειάζεται να γίνει κάποια προσθήκη μιας νέας τοπολογίας στο δίκτυο, γίνεται εύκολα χωρίς να χρειάζεται να προγραμματιστούν ξανά οι συσκευές του δικτύου. [71]

Τα δίκτυα λόγω της ανάπτυξης των υπηρεσιών που προσφέρουν οι υπηρεσίες βίντεο μέσω διαδικτύου, οι streaming υπηρεσίες κ.α. τα δίκτυα packet-switch φαίνεται πως βιώνουν μια αυξημένη ροή πληροφοριών οι οποίες μεταδίδονται στους κόμβους της [72]. Λόγω της αρκετά αυξημένης κυκλοφορίας των πακέτων, οι συμβατικοί αλγόριθμοι δρομολόγησης δεν είναι ικανοί να αποσυμφορίσουν το δίκτυο με επιτυχία, για αυτό τον λόγο η έρευνα με όνομα “Machine Learning Aided Load Balance Routing Scheme Considering Queue Utilization” [73] προτείνει ένα έξυπνο σχήμα δρομολόγησης (routing scheme) για να γίνει μια προσπάθεια προς την επίλυση των προβλημάτων αλγόριθμων δρομολόγησης QoS.

Ο Multiple-Constrained Path (MCP) είναι ένας αλγόριθμος ο οποίος ανήκει στους αλγόριθμους συνδυαστικής βελτιστοποίησης. Χρησιμοποιείται συνήθως για την εύρεση διαθέσιμων μονοπατιών τα οποία ικανοποιούν πολλαπλούς περιορισμούς. Εάν οι περιορισμοί του προβλήματος είναι ανεξάρτητοι τότε, το πρόβλημα θεωρείται ως NP-complete. NP-complete ονομάζονται τα προβλήματα εκείνα τα οποία: Η ορθότητα κάθε λύσης τους μπορεί να επαληθευτεί γρήγορα και μία λύση μπορεί να βρεθεί δοκιμάζοντας όλες τις πιθανές λύσεις, χρησιμοποιώντας αλγορίθμους Brute Force (ωμής βίας). Επίσης ιδιαίτερη σημασία έχει δοθεί στην δρομολόγηση με αλγόριθμους Quality of Service (QoS) έτσι ώστε να επιτευχθεί σταθερότητα και αποδοτικότητα σε ένα δίκτυο [74]. Οι περισσότεροι αλγόριθμοι τύπου QoS λαμβάνουν υπόψιν πολλούς περιορισμούς και οι λύσεις είναι εφικτές με μία θεωρητικά αποδεκτή υπολογιστική πολυπλοκότητα.

Οι ευρετικοί (heuristic) αλγόριθμοι τείνουν να είναι αργοί όσον αφορά την ταχύτητα αντιμετώπισης προβλημάτων που βρίσκονται σε μεγάλη κλίμακα. Επίσης, οι λύσεις που δίνονται είναι βασισμένες σε μία σειρά από ιδανικές υποθέσεις αλλά, σε κάποιες περιπτώσεις είναι λανθασμένες. Επιπρόσθετα, λόγω αρκετών περιορισμών που έχουν οι αλγόριθμοι QoS, ισχύει πως η ιδανική διαδρομή των δεδομένων ίσως να μην είναι διαθέσιμη προς όλους.

Οι έρευνα ουσιαστικά χωρίζεται σε 3 μέρη :

- Το πρώτο ονομάζεται Topology Feature Learning (Εκμάθηση χαρακτηριστικών τοπολογίας) και αυτό που κάνει είναι να χρησιμοποιεί τον αλγόριθμο μείωσης διάστασης PCA στην εξαχθείσα τοπολογία η οποία μπορεί να χρησιμοποιηθεί αποδοτικά για την εκπροσώπηση των συνδέσεων των δρομολογητών στο δίκτυο .
- Το δεύτερο μέρος ονομάζεται Machine Learning Based Prediction και γίνεται χρήση ενός αλγορίθμου τύπου Νευρωνικού Δικτύου και εφόσον ληφθεί υπόψη η σχέση ανάμεσα στην κίνηση που επικρατεί σε ένα δίκτυο, την τοπολογία του δικτύου και τις καταστάσεις των δρομολογητών, προβλέπει την QU στην επόμενη χρονική στιγμή και χρησιμοποιείται ως μετρική για την έξυπνη δρομολόγηση.
- Το τρίτο μέρος έχει να κάνει με δύο σχήματα δρομολόγησης εν ονόματι MLQU και DLQU. Αυτοί είναι δύο αλγόριθμοι οι οποίοι λαμβάνουν υπόψη την κίνηση που υπάρχει σε ένα δίκτυο, έπειτα χρησιμοποιούν την παράμετρο QoS της συνδεσιμότητας ενός δικτύου, την κατάσταση της κίνησης και τον αριθμό των hops.


Αφού τελείωσε η διαδικασία εκπαίδευσης των αλγορίθμων στην συνέχεια αξιολογήθηκε η απόδοση αλγορίθμων. Ένα μέτρο αξιολόγησης που χρησιμοποιείται είναι το Mean Square Error (MSE) ή αλλιώς LOSS, το οποίο είναι ο μέσος όρος του τετραγώνου της διαφοράς μεταξύ των κανονικών τιμών και των τιμών που έχουν προβλεφθεί.

$$MSE = \frac{1}{N} \sum_{j=1}^N (predicted - input)^2$$

Τα αποτελέσματα της εκπαίδευσης έδειξαν πως στην προκειμένη περίπτωση όσο αυξάνεται το learning rate τόσο αυξάνεται και το loss (βλ. Εικόνα 14). Φαίνεται πως η καλύτερη επιλογή είναι το 0,025 καθώς εκεί το loss για το training test και για το test set φαίνεται να είναι στο ελάχιστο σημείο του.

Επίσης φαίνεται πως το loss μειώνεται συνεχώς όσο αυξάνονται οι εποχές. Το πρόβλημα το οποίο δημιουργείται είναι πως όσο οι εποχές αυξάνονται τότε εμφανίζεται το πρόβλημα του overfitting, οπότε ο καλύτερος αριθμός εποχών φάνηκε πως είναι ο αριθμός 5000 (βλ. Εικόνα 14: Η απόδοση στο training set και στο test set (βλ. Εικόνα 14 (b))).

Όπως φαίνεται στην Εικόνα 14(c) το ρηχό νευρωνικό δίκτυο(shallow neural network) απέδωσε καλύτερα στην μείωση του loss μεταξύ εξόδου και ετικέτας.




Εικόνα 14: Η απόδοση στο training set και στο test set

Στην Εικόνα 15(a) φαίνεται το PLR (τα πακέτα τα οποία δεν έφτασαν στον προορισμό τους διαιρεμένα με επιπλέον πακέτα στο IP layer) με διαφορετικό σχήμα κινητικότητας (traffic pattern). Ο βασικός σκοπός των δικτύων packet-switch είναι η μετάδοση όσο περισσότερων πακέτων γίνεται στο δίκτυο. Φαίνεται πως στα προτεινόμενα σχήματα δρομολόγησης το PLR έχει χαμηλότερες τιμές .

Στην Εικόνα 15(b) φαίνεται η παραγωγικότητα (ο αριθμός των επιτυχών παραδομένων πακέτων ανά μονάδα χρόνου) με διαφορετικά σχήματα κινητικότητας (traffic pattern). Η μέση παραγωγικότητα δεν βοηθάει στην εξαγωγή συμπερασμάτων για το ισοζύγιο του φορτίου, οπότε χρησιμοποιούνται οι χειρότερες τιμές της αποδοτικότητας των τεσσάρων αλγορίθμων που χρησιμοποιούνται. Όσο υψηλότερη είναι η χειρότερη τιμή της παραγωγικότητας, τόσο καλύτερα αποδίδει το δίκτυο στο ισοζύγιο φορτίου. Φαίνεται πως οι αλγόριθμοι MLQU και DLQU έχουν την υψηλότερη παραγωγικότητα στο δίκτυο και πως το σχήμα δρομολόγησης έχει επιτευχθεί.

Η Εικόνα 15(c) δείχνει την μέση καθυστέρηση σε μεταβαλλόμενα σχήματα κινητικότητας. Όσο μικρότερη είναι η καθυστέρηση, τόσο καλύτερη είναι η εμπειρία χρήσης για τον χρήστη. Φαίνεται στους αλγορίθμους MLQU και DLQU ότι είναι μεγαλύτερη κατά 20% σε σχέση με το BF. Φαίνεται πως σε συνδυασμό με το BF η πρόταση

της έρευνας δείχνει να μπορεί να επιλέξει τον δρομολογητή με τους λιγότερους πόρους buffer για επόμενο hop καθώς και να μειώσει την καθυστέρηση της ουράς.



Εικόνα 15: Η απόδοση των σχημάτων δρομολόγησης

4 Λοιπές χρήσεις της Μηχανικής Μάθησης στα δίκτυα

Σε αυτό το κεφάλαιο θα αναλυθούν χρήσεις τεχνικών Μηχανικής Μάθησης σε περιοχές των δικτύων λοιπές από την δρομολόγηση σε αυτά.

4.1 Χρήσεις του Edge Learning στα ασύρματα δίκτυα

Με την πάροδο των χρόνων και την αύξηση της κίνησης των δεδομένων στα δίκτυα καθώς και την ανάπτυξη των τεχνολογιών της Τεχνητής Νοημοσύνης, σαν αποτέλεσμα φαίνεται η ανάγκη χρήσης της με σκοπό την χρήση αυτών των δεδομένων για την βελτίωση της ποιότητας της ζωής των ανθρώπων. Μεγάλο ρόλο στην αύξηση αυτή της κίνησης στα δίκτυα φαίνεται πως αποτελούν οι edge συσκευές, οι οποίες είναι συσκευές οι οποίες ελέγχουν την ροή δεδομένων στα άκρα μεταξύ δύο δικτύων. Οι συσκευές αυτές μπορούν να χρησιμοποιηθούν για διάφορους λόγους ανάλογα με τον τύπο τους, αλλά συνήθως χρησιμεύουν ως σημεία εισόδου ή εξόδου σε ένα δίκτυο [75]. Επιπλέον καθώς παρατηρείται εξέλιξη σε αυτό τον τομέα δημιουργείται επίσης η ανάγκη της επένδυσης σε τεχνολογίες οι οποίες θα χρησιμοποιούν έξυπνη edge τεχνολογία για να στηριχθούν εφαρμογές όπως εφαρμογές έξυπνης πόλης (smart city), e-Banking, έξυπνης μετακίνησης κ.α. Αυτή η ανάγκη οδήγησε στην εμφάνιση μιας νέας ερευνητικής περιοχής η οποία ονομάζεται μάθηση edge (edge learning), η οποία αναφέρεται στην χρήση αλγορίθμων μηχανικής

μάθησης (μάθηση με επίβλεψη, μάθηση χωρίς επίβλεψη και μάθηση με επιβράβευση) σε edge συσκευές.

Μέχρι πρότινος η εκπαίδευση απαιτητικών μοντέλων μηχανικής μάθησης χρειαζόταν μεγάλη υπολογιστική ισχύ και μπορούσε να υποστηριχθεί από δυνατούς cloud servers. Καθώς αναπτύσσεται η edge τεχνολογία, η εκπαίδευση αυτών των μοντέλων γίνεται πλέον και σε edge servers καθώς επίσης και σε κινητές συσκευές με έναν ικανοποιητικό βαθμό επεξεργαστικής ισχύς. Η ύπαρξη μάθησης στο cloud, σε κάποιον edge server καθώς και σε κινητές συσκευές έχει δημιουργήσει μια πολυεπίπεδη αρχιτεκτονική για την χρήση μηχανικής μάθησης μέσα στο δίκτυο (βλ. Εικόνα 16) [76]. Κάθε διαφορετικό επίπεδο διαθέτει διαφορετικές επεξεργαστικές και χωρικές δυνατότητες και χρησιμοποιείται για διαφορετικά σενάρια μάθησης.

Η edge εκμάθηση σε σχέση με την εκμάθηση σε συσκευές (On-device learning) και σε σχέση με τη μάθηση στο cloud (cloud learning) έχει ένας σαφές προβάδισμα, καθώς έχει την πιο ισορροπημένη υποστήριξη πόρων και επίσης οι πηγές δεδομένων που χρησιμοποιούνται είναι όμοιες. Η εκμάθηση edge ξεπερνά σε απόδοση την εκμάθηση στο cloud η οποία αποτυγχάνει να επεξεργαστεί δεδομένα σε πραγματικό χρόνο και ξεπερνά επίσης σε απόδοση την εκμάθηση σε συσκευές, καθώς επιτυγχάνει πολύ καλύτερη ακρίβεια λόγω της ικανότητας υποστήριξης αρκετά πολύπλοκων μοντέλων και της συγκέντρωσης δεδομένων από πολλές συσκευές.

Λόγω των δυνατοτήτων της, η μάθηση edge μπορεί να χρησιμοποιηθεί σε ένα μεγάλο εύρος μοντέλων μηχανικής μάθησης και εφαρμογών, όπως π.χ. εφαρμογές αυτόνομης οδήγησης και εικονικής πραγματικότητας. Για αυτές τις εφαρμογές πρέπει να γίνει εκπαίδευση σε πραγματικό χρόνο και για αυτό πρέπει να χρησιμοποιείται πολύ γρήγορη online εκπαίδευση που μπορεί τα δεδομένα να αγγίζουν τον αριθμό των εκατομμυρίων. Για τον λόγο αυτό, κλίνεται απαραίτητο η χρήση της μάθησης edge να μπορεί να ανταπεξέρχεται γρήγορα σε προκλήσεις (στο παράδειγμα της αυτόνομης οδήγησης θα πρέπει το αυτοκίνητο να είναι ικανό να ανταπεξέλθει χωρίς την παραμικρή καθυστέρηση). Ωστόσο υπάρχει πρόβλημα με την ασύρματη τεχνολογία καθώς δεν είναι σε θέση να υποστηρίξει τις απαιτήσεις ενός τέτοιου εγχειρήματος. Ο λόγος είναι πως ο σχεδιασμός των ασύρματων δικτύων δεν προσφέρει την αξιοπιστία που χρειάζεται για να υποστηριχθεί το edge learning. Πιο συγκεκριμένα, λόγω των τεράστιων ποσοτήτων δεδομένων που κατακλύζουν το δίκτυο δημιουργούνται προβλήματα καθυστέρησης,

πράγμα το οποίο επηρεάζει αρνητικά την πολύ γρήγορη διαδικασία μάθησης που απαιτείται από το edge learning.



Εικόνα 16: Η πολυεπίπεδη αρχιτεκτονική για την χρήση Μηχανικής Μάθησης μέσα στο δίκτυο

Στην μάθηση edge τα δεδομένα εκπαίδευσης συχνά είναι ευαίσθητα λόγω ιδιωτικότητας και μεγάλα σε ποσότητα, οπότε για αυτό τον λόγο όταν χρησιμοποιούνται για εκπαίδευση σε έναν edge server, υπάρχουν προβλήματα παραβίασης της ιδιωτικότητας και λόγω μεγέθους υπάρχει κόστος στην επικοινωνία του δικτύου. Αναλογιζόμενοι τα παραπάνω οι επιστήμονες έφτιαξαν ένα framework με όνομα “Federated learning” το οποίο μπορεί να αντιμετωπίσει αποτελεσματικά τα ζητήματα που αναφέρθηκαν παραπάνω τοπικά χωρίς να χρειάζεται όλα τα δεδομένα να μεταφέρονται στον server.

Ο βασικός σχεδιαστικός στόχος της εκμάθησης edge είναι η γρήγορη απόκτηση “νοημοσύνης” από δεδομένα πλούσια και υψηλά κατανεμημένα στις edge συσκευές που εμπλέκονται στην εκμάθηση. Για να λειτουργήσει σωστά το παραπάνω εγχείρημα εξαρτάται από την ικανότητα των server να επεξεργάζονται δεδομένα καθώς και στην σωστή επικοινωνία μεταξύ συσκευών edge και edge servers. Λόγω της αυξανόμενης επεξεργαστικής ισχύς στους edge servers, η επικοινωνία μεταξύ των υποδοχών των ασύρματων καναλιών αντιμετωπίζει προβλήματα εξαιτίας φαινομένων απώλειας διάδοσης, σκίασης και εξασθένησης και αυτό έχει ως αποτέλεσμα την καθυστέρηση της γρήγορης μάθησης που χρειάζεται.

Δυστυχώς ο σχεδιασμός των ασύρματων τεχνολογιών δεν ευνοεί την εκμάθηση edge και για αυτό στο άρθρο “Toward an Intelligent Edge: Wireless Communication Meets Machine Learning” έχουν προταθεί λύσεις για την διόρθωση των προβλημάτων και παρουσιάζονται παραδείγματα edge μάθησης και της απόδοσης της σε ασύρματα δίκτυα.

Η καινοτομία της έρευνας εν ολίγοις εστιάζει στην μάθηση, με βάση δεδομένα και στον υπολογισμό κάποιας συνάρτησης αθροίσματος πολλαπλών δειγμάτων αντί να αποκωδικοποιεί υπάρχοντα μεμονωμένα δείγματα όπως προτείνουν τα υπάρχοντα σχήματα. Η έρευνα προτείνει την παρακάτω κατευθυντήρια γραμμή:

“Οι μοναδικές ιδιότητες των ασύρματων καναλιών όπως π.χ. η εκπομπή και η υπέρθεση (superposition), θα πρέπει να χρησιμοποιούνται για τον υπολογισμό της συνάρτησης χρησιμοποιώντας τα κατανεμημένα δεδομένα για την επιτάχυνση της εκμάθησης edge.”

Σε σχέση με την παραπάνω κατευθυντήρια γραμμή έχει παρατηρηθεί πως αν χρησιμοποιηθεί γραμμική-αναλογική διαμόρφωση και προκαναλική αντιστάθμιση στον πομπό οι παρεμβολές που προκαλούνται από την γρήγορη συγκέντρωση δεδομένων μπορούν να αξιοποιηθούν για γρήγορη συγκέντρωση δεδομένων. Το παραπάνω έχει προταθεί πρόσφατα και ονομάζεται “AirComp”. Το AirComp επειδή επιτρέπει ταυτόχρονη μετάδοση, μπορεί να μειώσει δραματικά την καθυστέρηση πολλαπλής πρόσβασης κατά παράγοντα ίσο με τον αριθμό των χρηστών ξεπερνώντας τα χρονικά προβλήματα με της edge μάθησης.

Σε δοκιμές που έγιναν για τη σύγκριση του AirComp με το OFDMA φάνηκε πως το AirComp αποδίδει καλύτερα από το OFDMA σε περιπτώσεις όπου ο λόγος σήματος θορύβου είναι χαμηλός. Το AirComp φάνηκε επίσης να έχει μειώσει σημαντικά την καθυστέρηση από 10 σε έως 1000 φορές.

Με την παραδοσιακή υπολογιστική προσέγγιση διαχωρισμού των επικοινωνιών, οι υπάρχουσες μέθοδοι διαχείρισης πόρων (RRM) είναι σχεδιασμένες για την μεγιστοποίηση της φασματικής απόδοσης με την σωστή κατανομή των πόρων (ισχύς, ζώνη συχνοτήτων κ.τ.λ.). Ωστόσο, το παραπάνω δεν είναι αποτελεσματικό στην εκμάθηση edge. Αυτό προέτρεψε τους ερευνητές να ορίσουν και άλλη κατευθυντήρια γραμμή η οποία είναι η παρακάτω:


“Οι πόροι θα πρέπει να κατανέμονται με βάση την τιμή μετάδοσης των δεδομένων για την βελτίωση της μαθησιακής απόδοσης”

Το κλασσικό RRM υποθέτει ότι κάθε διαφορετικό μήνυμα έχει την ίδια αξία για τον παραλήπτη. Η υπόθεση αυτή κάνει την μεγιστοποίηση του αθροίσματος-ρυθμού βασικό κριτήριο σχεδιασμού. Στην εκμάθηση edge ο παραπάνω σχεδιασμός δεν είναι αποδοτικός καθώς κάποια μηνύματα όπως είναι φυσικό έχουν μεγαλύτερη αξία από άλλα για την εκπαίδευση ενός μοντέλου.

Με βάση την παραπάνω κατευθυντήρια γραμμή προτείνεται μια τεχνική η οποία ονομάζεται “importance-aware resource allocation” η οποία λαμβάνει υπόψιν την σημασία των δεδομένων. Η τεχνική αυτή μοιάζει με την τεχνική με όνομα “active learning” η οποία χρησιμοποιείται για την εύρεση σημαντικών χαρακτηριστικών μέσα από ένα μεγάλο σετ δεδομένων το οποίο δεν έχει κατηγοριοποιηθεί. Στην importance-aware resource allocation υπάρχει μεγαλύτερη δυσκολία καθώς εκτός από την σημαντικότητα των δεδομένων πρέπει να ληφθεί υπόψιν και η πηγή των radio πόρων για την εξασφάλιση των μεταδιδόμενων δεδομένων.

Το RRM μπορεί να καθοριστεί ως εξής: αφορά τις πόσες αναμεταδόσεις θα γίνουν για ένα συγκεκριμένο δείγμα δεδομένων. Σε κάθε επικοινωνία ο server θα πρέπει να αποφασίσει δυαδικά για το αν θα επιλέξει μια νέα συσκευή και ένα νέο δείγμα δεδομένων ή θα αναμεταδώσει το ήδη υπάρχον δείγμα δεδομένων για την βελτίωσή του.

Μετά τη διεξαγωγή πειράματος (βλ. Εικόνα 17) [76] για την απόδοση του RRM διαπιστώθηκε πως αν το δείγμα των δεδομένων περιέχει υψηλά επίπεδα θορύβου και δεν γίνει κάποια αναμετάδοση τότε η απόδοση μειώνεται δραματικά όσο αυξάνονται τα δείγματα. Αυτό συμβαίνει επειδή ο θόρυβος συσσωρεύεται και προκαλεί απόκλιση του μοντέλου, πράγμα που δικαιολογεί την ανάγκη χρήσης της importance-aware αναμετάδοσης η οποία είναι καλύτερη επιλογή σε σχέση με την απόδοση με χρήση κλασσικής αναμετάδοσης. [76]



Εικόνα 17: Η απόδοση του πειράματος.


4.2 Πρόβλεψη της κάλυψης σε ένα ασύρματο δίκτυο

Στα τηλεπικοινωνιακά δίκτυα συχνά αναφέρεται ο όρος “Κάλυψη” και αναφέρεται στην γεωγραφική περιοχή στην οποία ένας πομπός μπορεί να εκπέμπει σήματα και ο δέκτης σε εκείνη την περιοχή και μόνο μπορεί να τα λάβει. Η κάλυψη είναι εξαρτώμενη από πολλούς παράγοντες όπως για παράδειγμα βουνά, κτίρια, τεχνολογικές ικανότητες, ραδιοσυχνότητες κ.α. [77]

Η έρευνες οι οποίες έχουν περατωθεί έως τώρα έχουν δείξει πως μπορεί να γίνει πρόβλεψη της κάλυψης χρησιμοποιώντας στοχαστική γεωμετρία. Το πρόβλημα είναι πως τα σενάρια στα οποία έχουν γίνει τα πειράματα δεν είναι ρεαλιστικά. Παρακάτω θα γίνει ανάλυση των αποτελεσμάτων μίας έρευνας.


Στην έρευνα αυτή με όνομα “A Machine Learning Approach to Predicting Coverage in Random Networks” [78] που έγινε από ερευνητές από το πανεπιστήμιο του Radat στο Μαρόκο γίνεται μια προσέγγιση πρόβλεψης της κάλυψης σε ένα τηλεπικοινωνιακό δίκτυο με χρήση Νευρωνικών Δικτύων.

Αρχικά έγιναν προσομοιώσεις διαφόρων σεναρίων δικτύων και τα αποτελέσματα τους χρησιμοποιήθηκαν για την δημιουργία σετ δεδομένων με σκοπό την κατανόηση της σχέσης μεταξύ των παραμέτρων και να προβλεφθεί η πιθανότητα κάλυψης για κάθε είδος δικτύου χωρίς να χρειάζεται να γίνουν κλασικές προσομοιώσεις. Τα σετ δεδομένων που δημιουργήθηκαν περιείχαν χαρακτηριστικά δικτύων όπως: εκθέτης απώλειας διαδρομής (path loss exponent), πυκνότητα σταθμών βάσης (base stations density), αναλογία ισχύος προς θόρυβο, διακύμανση σκίασης κ.α. Τα δεδομένα αυτά στην συνέχεια χρησιμοποιήθηκαν για την εκπαίδευση ενός νευρωνικού δικτύου (Εικόνα 18) [78]



Εικόνα 18: Το Νευρωνικό Δίκτυο που χρησιμοποιήθηκε

Τα αποτελέσματα που πάρθηκαν έδειξαν πως το Νευρωνικό Δίκτυο εξαιρετικά αποτελέσματα στην πρόβλεψη της κάλυψης σε διάφορα σενάρια (βλ. Εικόνα 19) [78]



Εικόνα 19: Τα αποτελέσματα των προβλέψεων του Νευρωνικού Δικτύου και τα αποτελέσματα υπολογισμένα από προσομοίωσης Monte Carlo

4.3 Αύξηση της ασφάλειας σε δίκτυα 5G με χρήση τεχνικών Μηχανικής Μάθησης

Τα δίκτυα 5G έχουν αρχίσει σιγά σιγά να εξαπλώνονται παγκόσμια και μαζί με αυτή την εξάπλωση έρχονται πολλές βελτιώσεις.

Το 5G είναι το δίκτυο κινητής τηλεφωνίας το οποίο ανήκει στην 5^η γενιά δικτύων. Είναι ένα νέο παγκόσμιο ασύρματο πρότυπο το οποίο έχει αρχίσει να επικρατεί μετά τα δίκτυα 1G, 2G, 3G, και 4G. Είναι ένα νέο είδος δικτύου το οποίο έχει σχεδιαστεί για να συνδέει πολλές συσκευές ταυτόχρονα μαζί.

Η τεχνολογία 5G είναι σχεδιασμένη να μεταφέρει υψηλό αριθμό δεδομένων το δευτερόλεπτο (θεωρητικά μπορεί να μεταφέρει μέχρι 20 Gbps, σε αντίθεση με τα 4G δίκτυα τα οποία ήταν ικανά να μεταφέρουν μέχρι 1Gbps), να έχει πολύ μικρή καθυστέρηση στην παράδοση των δεδομένων, να είναι πιο αξιόπιστη, να έχει τεράστια χωρητικότητα δικτύου, βελτιωμένη εμπειρία χρήσης κ.α. [79] [80]

Το πρόβλημα αυτής της γενιάς δικτύων είναι πως λόγω της ασύρματης συνδεσιμότητας σε πολλές συσκευές ταυτόχρονα, παρουσιάζουν ευπάθειες σε επιθέσεις spoofing.

Spoofing ονομάζονται οι επιθέσεις κατά τις οποίες ο επιτιθέμενος μιμείται κάποιον έμπιστο αποστολέα δεδομένων και σκοπό έχει να παραπλανήσει τα θύματά του με σκοπό να υποκλέψει κάποια δεδομένα (τραπεζικά δεδομένα, εταιρικά δεδομένα, προσωπικά δεδομένα κ.τ.λ.).

Οι επιθέσεις αυτές μπορούν να έχουν πολλές μορφές, όπως οι επιθέσεις email spoofing οι οποίες γίνονται με σκοπό να “ψαρέψουν” στοιχεία από τα θύματα τους (ονόματα χρηστών, κωδικούς κ.τ.λ.) τα οποία χρησιμοποιούνται για να διαπραχθεί κάποια απάτη, αλλά μπορεί να στοχεύουν και σε πιο τεχνικούς στόχους όπως το δίκτυο ενός οργανισμού (διευθύνσεις IP, DNS server, ARP κ.τ.λ.) και να κάνει επιθέσεις όπως η “Man in the Middle” και η denial-of-service.

Οι επιθέσεις αυτές μπορεί να έχουν πολύ σοβαρό αντίκτυπο καθώς ο επιτιθέμενος μπορεί να κλέψει ευαίσθητα προσωπικά δεδομένα, πληροφορίες κάποιας εταιρείας, στοιχεία σύνδεσης τα οποία μπορεί να χρησιμοποιήσει για να διαπράξει κάποια απάτη, να εξαπλώσει κάποιο κακόβουλο λογισμικό κ.α.

Για την πιο εύκολη κατανόηση των παραπάνω τα παραπάνω παραθέτω ένα παράδειγμα: Ας υποθέσουμε ότι υπάρχει μια επικοινωνία μεταξύ του Bob και της Alice και υπάρχει ένας τρίτος η Eve η οποία ονομάζεται spoofer και σκοπός της είναι να υποκλέψει τα μηνύματα του Bob, μιμούμενη κατά την επικοινωνία την Alice. Σκοπός του Bob είναι να βρísκεται σε θέση να καταλάβει πότε τα μηνύματα προέρχονται από την Alice και να απαντήσει και πότε προσπαθούν να τον ξεγελάσουν. Αυτό το παράδειγμα επίθεσης ονομάζεται Man in the middle attack και είναι ένας είδος επίθεσης spoofing. [81] [82] [83]

Για την λύση αυτού του προβλήματος έχουν μελετηθεί κρυπτογραφικές τεχνικές οι οποίες φάνηκε πως έχουν ένα ποσοστό επιτυχίας. Οι αδυναμίες των κρυπτογραφικών τεχνικών όμως σε δίκτυα 5G και μεγαλύτερα (6G και άνω) τις κάνουν ακατάλληλες προς χρήση. Οι αδυναμίες αυτές είναι η αυξημένη καθυστέρηση, τα έξοδα επικοινωνίας για την επίτευξη καλύτερων επιδόσεων ασφαλείας, τα οποία είναι εξαιρετικά ανεπιθύμητα για επικοινωνίες ευαίσθητες σε καθυστερήσεις και σε συσκευές με περιορισμένους πόρους.

Επίσης για την λύση αυτού του προβλήματος έχει προταθεί η αυθεντικοποίηση μιας συσκευής μέσω του φυσικού επιπέδου το οποίο έχει θετικά όπως το ότι δεν έχει μεγάλες υπολογιστικές απαιτήσεις και το δίκτυο δεν έχει πολλά έξοδα (ενεργειακά κ.α.). Αυτό μπορεί να συμβεί μέσω εκμετάλλευσης των χαρακτηριστικών σύνδεσης, επικοινωνίας, συσκευής και τοποθεσίας, απόκριση συχνότητας καναλιού κ.α.

Η αυθεντικοποίηση μέσω του φυσικού επιπέδου μπορεί να έχει κάποια θετικά αλλά, αντιμετωπίζει αρκετές προκλήσεις. Ο βασικός λόγος των προκλήσεων αυτών είναι πως οι υπάρχουσες τεχνικές ελέγχου ταυτότητας στο φυσικό επίπεδο βασίζονται σε στατικούς μηχανισμούς και αυτό έρχεται σε αντίθεση με το πολύπλοκο και δυναμικό περιβάλλον των 5G δικτύων. Παρακάτω αναφέρονται εν ολίγοις οι προκλήσεις:

- Χαμηλή αξιοπιστία κατά τη χρήση ενός μοναδικού χαρακτηριστικού: Η απόδοση των σχημάτων ελέγχου ταυτότητας στο φυσικό επίπεδο πάσχει από ατελείς εκτιμήσεις και παραλλαγές του επιλεγμένου χαρακτηριστικού.
- Δυσκολία στον προ-σχεδιασμό μιας λειτουργίας ακριβής αυθεντικοποίησης: Τα περισσότερα σχήματα ελέγχου είναι βασισμένα σε μοντέλα, πράγμα το οποίο σε συνδυασμό με ένα περίπλοκο χρονικά μεταβαλλόμενο περιβάλλον, χρειάζεται τεράστια ποσά δεδομένων για τη σωστή λειτουργία του.
- Ανικανότητα συνεχούς προστασίας των συσκευών: Κατά το μεγαλύτερο μέρος του υπάρχοντος ελέγχου ταυτότητας τα σήματα αυθεντικοποίησης είναι στατικά και δυαδικά, αυτό πρακτικά σημαίνει ότι συσκευές κατά τον έλεγχο ταυτότητας είτε θα περάσουν είτε θα αποτύχουν οδηγώντας το σύστημα σε μία και μοναδική επαλήθευση. Εάν δυο συσκευές έχουν επαληθευτεί και κατά την διάρκεια επικοινωνίας κάποιος προσπαθήσει να κάνει κάποια επίθεση spoofing, τότε το σύστημα δεν θα είναι ικανό να καταλάβει την επίθεση.
- Δυσκολία μάθησης με χρήση χαρακτηριστικών εναλλασσόμενων χρονικά: Η απόδοση της αυθεντικοποίησης και των υπάρχοντων σχημάτων αυθεντικοποίησης μπορούν να επηρεάζονται σοβαρά από τις απρόβλεπτες αλλαγές των χαρακτηριστικών λόγω της πιθανής αποσυσχέτισης σε διαφορετικές χρονικές στιγμές.

Σε ένα άρθρο με τίτλο “Machine Learning For Intelligent Authentication In 5G And Beyond Wireless Networks” οι ερευνητές οραματίζονται έξυπνες προσεγγίσεις

αυθεντικοποίησης με την βοήθεια της μηχανικής μάθησης για την αντιμετώπιση των προαναφερθέντων προκλήσεων.

Τα 5G δίκτυα αναμένεται να παρέχουν ευρείες υπηρεσίες με υψηλές επιδόσεις επικοινωνίας, ταχύτητας μετάδοσης των δεδομένων και ασφάλειας. Επίσης, κατά την διάρκεια των αναμεταδόσεων δεν θα πρέπει να υπάρχει ανησυχία υποκλοπής προσωπικών δεδομένων. Βάση αυτών των απαιτήσεων ο έξυπνος έλεγχος ταυτότητας κρίνεται απαραίτητος για την επίτευξη υψηλής αξιοπιστίας, ανεξαρτησίας μοντέλου, συνεχή προστασία, επίγνωση της κατάστασης του δικτύου κ.α..

Για την επιτυχία των παραπάνω με την βοήθεια της μηχανικής μάθησης θα πρέπει να υπάρχει:

- Υψηλή απόδοση κόστους: Λόγω του αυξημένου αριθμού συσκευών στα δίκτυα 5G, τόσο η επικοινωνία όσο και η διαχείριση ασφάλειας θα πρέπει να εκτελούνται ταυτόχρονα για να υπάρχει έγκυρη αυθεντικοποίηση η οποία δεν θα κοστίζει σε χρόνο και πόρους.
- Υψηλή αξιοπιστία: Τα πολυδιάστατα χαρακτηριστικά όπως ο χρόνος, η συχνότητα, η αρχιτεκτονική του δικτύου κ.α., παρέχουν υψηλότερη προστασία στους χρήστες οι οποίοι είναι αυθεντικοποιημένοι. Με την χρήση μηχανικής μάθησης μπορεί διευκολυνθεί ο έλεγχος ταυτότητας αναλύοντας τα πολυδιάστατα δεδομένα.
- Ανεξαρτησία του μοντέλου: Ένα σχήμα βασισμένο σε δεδομένα τα οποία θα χρησιμοποιηθούν με τεχνικές μηχανικής μάθησης μπορεί να ξεπεράσει τις δυσκολίες της διαδικασίας αυθεντικοποίησης.
- Συνεχόμενη προστασία: Εάν αξιοποιηθούν οι ληφθείσες πληροφορίες και χρησιμοποιηθούν μαζί με τις πληροφορίες για την ανταλλαγή δεδομένων μεταξύ των κόμβων, τότε με την βοήθεια μηχανικής μάθησης είναι πιθανόν η αυθεντικοποίηση να γίνεται σωστότερα και ασφαλέστερα και τα ρίσκα ασφαλείας να ελαχιστοποιηθούν.
- Επίγνωση της κατάστασης: Η αυθεντικοποίηση η οποία λαμβάνει επίγνωση της κατάστασης του δικτύου, “παρατηρεί” τους κίνδυνους ασφαλείας και “μαθαίνει” από το πολύπλοκο δυναμικό περιβάλλον με κύριο μέλημα την βελτίωση της ασφάλειας. Με την χρήση Μηχανικής Μάθησης η παραπάνω

διαδικασία μπορεί να γίνει πιο αποδοτικά καθώς μπορεί με τα διαθέσιμα δεδομένα να ληφθούν ασφαλέστερα συμπεράσματα.

Στην συνέχεια δίνονται κάποια παραδείγματα αυθεντικοποίησης με την χρήση τεχνικών Μηχανικής Μάθησης.

Στην αρχή η έρευνα αναφέρεται σε παραμετρικές και μη παραμετρικές μεθόδους και τις πιθανές χρήσεις τους στο πρόβλημα της αυθεντικοποίησης..

Συχνά στην Μηχανική Μάθηση υπάρχει μια συνάρτηση εκμάθησης (F) η οποία αντιστοιχίζει τις μεταβλητές εισόδου (X) στις μεταβλητές εξόδου (Y)

$$Y = F(x)$$

Οι αλγόριθμοι μαθαίνουν αυτές τις τιμές στόχους από τα δεδομένα εκπαίδευσης. Ο κάθε αλγόριθμος που χρησιμοποιείται κάνει διαφορετικές υποθέσεις για το πως πρέπει να προσεγγιστεί η συνάρτηση με σκοπό την εκμάθησή της. Οι υποθέσεις αυτές μπορούν απλοποιήσουν σε μεγάλο βαθμό την διαδικασία της μάθησης, ωστόσο μπορούν και να την περιορίσουν. Οι αλγόριθμοι οι οποίοι απλοποιούν τις συναρτήσεις σε μια γνώριμη μορφή ονομάζονται αλγόριθμοι παραμετρικής μάθησης. Η βασική ιδέα είναι ότι υπάρχει ένα σετ σταθερών παραμέτρων οι οποίες χρησιμοποιούνται για να προσδιορίσουν την συνάρτηση εκμάθησης, επίσης στις παραμετρικές μεθόδους υπάρχει εκ των προτέρων γνώση της κατανομής των δεδομένων η οποία συνήθως είναι η κανονική. [84]

Στην Μηχανική Μάθηση “Ένα μοντέλο μάθησης το οποίο συνοψίζει δεδομένα με ένα σύνολο παραμέτρων σταθερού μεγέθους (ανεξάρτητα από τον αριθμό των δειγμάτων εκπαίδευσης) ονομάζεται παραμετρικό μοντέλο. Ανεξάρτητα από τον αριθμό των δεδομένων που παρουσιάζονται σε ένα παραμετρικό μοντέλο, αυτό δεν θα αλλάξει το αποτέλεσμα του σχετικά με το πόσες παραμέτρους χρειάζεται” [85].

Κατά την διαδικασία αυθεντικοποίησης οι παραμετρικές μέθοδοι μάθησης μπορούν να μοντελοποιήσουν τα χαρακτηριστικά ξεχωριστά βασισμένες στην μορφή συγκεκριμένων συναρτήσεων και αυτό μπορεί να μειώσει την αβεβαιότητα που υπάρχει από το χρονικά μεταβαλλόμενο περιβάλλον. Ωστόσο στα δίκτυα 5G αυτή η μέθοδος πιθανών να είναι περιορισμένης χρήσης στην αυθεντικοποίηση συσκευών καθώς η εκ των προτέρων γνώση των χαρακτηριστικών και οι στατιστικές ιδιότητες είναι μη διαθέσιμες.

Οι αλγόριθμοι οι οποίοι δεν κάνουν υποθέσεις σχετικά με την μορφή της συνάρτησης ονομάζονται μη παραμετρικοί, καθώς δεν κάνουν υποθέσεις για την μορφή της συνάρτησης είναι ικανοί να μάθουν οποιαδήποτε μορφή συνάρτησης από τα δεδομένα εκπαίδευσης. Επιπροσθέτως οι παράμετροι που χρησιμοποιούνται και η κατανομή των δεδομένων δεν είναι γνωστοί. [84]

“Οι μη παραμετρικές μέθοδοι είναι χρήσιμες όταν δεν υπάρχουν πολλά δεδομένα και γνώση εκ των προτέρων και όταν δεν χρειάζεται να υπάρχει ανησυχία για την επιλογή των κατάλληλων χαρακτηριστικών”. [86]

Καθώς οι μη παραμετρικοί αλγόριθμοι μαθαίνουν δυναμικά από το χρονικά μεταβαλλόμενο περιβάλλον και δεν χρειάζεται να κάνουν υποθέσεις για την μορφή της συνάρτησης που έχουν να προβλέψουν, αυτό προσφέρει μεγαλύτερη ευελιξία για τα σενάρια “έξυπνης” αυθεντικοποίησης. Ειδικότερα τους προσφέρεται μεγαλύτερη ευελιξία στα σενάρια αυθεντικοποίησης που λαμβάνουν χώρα σε πραγματικό χρόνο όπου υπάρχει περιορισμός στους υπολογιστικούς και χρονικούς πόρους. Ωστόσο, σε σχέση με τις παραμετρικές μεθόδους μάθησης, απαιτούνται περισσότερα δεδομένα εκπαίδευσης και μπορεί να έχουν ως αποτέλεσμα το overfitting (υπεργενίκευση).

Στην συνέχεια αναλύονται τεχνικές μάθησης με επίβλεψη, μάθησης χωρίς επίβλεψη και μάθησης με επιβράβευση καθώς και οι πιθανές τους χρήσεις στην αυθεντικοποίηση με απώτερο σκοπό την ασφάλεια. Στην επιλογή μεταξύ αλγορίθμων μάθησης με επίβλεψη και αλγορίθμων μάθησης χωρίς επίβλεψη, η απόφαση επιλογής εξαρτάται από τον όγκο των δεδομένων και το πρόβλημα αυθεντικοποίησης.


Ένας αλγόριθμος μάθησης με επίβλεψη είναι κατάλληλος όταν τα δεδομένα εκπαίδευσης και οι τιμές στόχοι (τιμές εξόδου) μιας επικοινωνίας είναι εύκολα στην απόκτησή τους. Πιο συγκεκριμένα οι ετικέτες εξόδου πρέπει να αποκτώνται ακαριαία έτσι, ώστε η διαδικασία του ελέγχου ταυτότητας να μπορεί να επιτευχθεί σε πραγματικό χρόνο. Όταν οι ετικέτες εξόδου δεν είναι άμεσα διαθέσιμες, τότε τεχνικές γρήγορης εύρεσης των ετικετών μπορεί να φανούν χρήσιμες.

Για την επεξήγηση της χρήσης των αλγορίθμων μάθησης χωρίς επίβλεψη θα βασιστώ στο παράδειγμα που αναφέρθηκε παραπάνω. Ο Bob λαμβάνει αποκλειστικά δεδομένα εκπαίδευσης χωρίς ετικέτες και κάνει προβλέψεις για όλα τα δεδομένα που δεν έχει δει (αυτό μπορεί να γίνει με τον αλγόριθμο k-means). Σε σενάρια στα οποία τα δείγματα

της Alice είναι πολύ περισσότερα από αυτά της Eve (spoofers) θα μπορούν να χρησιμοποιηθούν αλγόριθμοι μάθησης χωρίς επίβλεψη για “έξυπνη” αυθεντικοποίηση της Alice. Κατά την αυθεντικοποίηση της Alice χρησιμοποιούνται αλγόριθμοι μάθησης χωρίς επίβλεψη και η ενεργειακή κατανάλωση για την ετικετοποίηση των εξόδων είναι σημαντικά μειωμένες.

Σε παρελθοντικές έρευνες οι οποίες αναφέρονται στο άρθρο που αναλύεται, έχουν χρησιμοποιηθεί τεχνικές μάθησης με επιβράβευση. Έχει παρατηρηθεί πως η ασφάλεια στην αυθεντικοποίηση δεν είναι σε καλά επίπεδα και σε αυτό το άρθρο αναφέρονται τρόποι αντιμετώπισης αυτού του φαινομένου. Με σκοπό την βελτίωση της ασφάλειας της επικοινωνίας προτείνεται να χρησιμοποιηθεί μια τεχνική με όνομα “masking-based privacy protection”. Με αυτή την τεχνική περατώνεται η ασφάλεια των δεδομένων κατά την μεταφορά τους στο δίκτυο.

Σε ένα πείραμα που έγινε με διάφορα χαρακτηριστικά μεταξύ κλασικών μεθόδων αυθεντικοποίησης και έξυπνων μεθόδων, φάνηκε πως με τις έξυπνες μεθόδους αυθεντικοποίησης υπάρχει πολύ μικρότερο ποσοστό εσφαλμένης ανίχνευσης (βλ. Εικόνα 20). [87]



Εικόνα 20: Σύγκριση κλασσικών στατικών τεχνικών αυθεντικοποίησης με έξυπνες τεχνικές αυθεντικοποίησης

5 Συμπεράσματα

Σε αυτό το κεφάλαιο θα αναλυθούν τα συμπεράσματα αυτής της πτυχιακής εργασίας.

5.1 Συμπεράσματα

Σε μια καθημερινότητα κατακλισμένη από δεδομένα και ενέργειες οι οποίες πρέπει να γίνονται εν ριπή οφθαλμού και αλάνθαστα φαίνεται πως με την τεχνολογική εξέλιξη που έχει επέλθει σε πολλούς τομείς ήταν αναμενόμενο πως χρειαζόταν να εξελιχθεί και ο τομέας των δικτύων για να συνεχίσει η ανάπτυξη. Υπάρχει αρκετό ερευνητικό ενδιαφέρον στον τομέα των δικτύων και πιο συγκεκριμένα στον τομέα των δικτύων σε συνδυασμό με την Μηχανική Μάθηση η οποία φαίνεται πως είναι ικανή να λύσει προβλήματα δρομολόγησης, δικτύωσης, διαχείρισης ενέργειας, κόστους, ασφάλειας κ.α. Ο κλάδος της Μηχανικής Μάθησης εν έτη 2022 ακμάζει και θεωρώ πως έχει να προσφέρει ακόμα πολλές λύσεις οι οποίες με την σειρά τους θα εξελίξουν και άλλο τον κλάδο των δικτύων.

Βιβλιογραφία

- [1] «www.techterms.com,» [Ηλεκτρονικό]. Available: <https://techterms.com/definition/network>. [Πρόσβαση 2 6 2021].
- [2] W. H. Richard fox, Internet Infrastructure: Networking, Web Services, and Cloud Computing 1st Edition, CRC Press, 2019.
- [3] R. B. James Edwards, Networking Self-Teaching Guide, Wiley Publishing, Inc, 2009.
- [4] M. S. Gast, 802.11 Wireless Networks: The Definitive Guide, 2nd Edition, O'Reilly Media, Inc., 2005.
- [5] K. Liang και M. Myers, «Machine Learning Applications in the Routing in Computer Networks,» *arXiv preprint arXiv:2104.01946*, 2021.
- [6] H. Xin, «Introduction of centralized and distributed routing protocols,» p. 2698–2701, 2011.
- [7] J. McCarthy, «What is artificial intelligence?,» 2007.
- [8] «www.wikipedia.com,» [Ηλεκτρονικό]. Available: https://el.wikipedia.org/wiki/%CE%86%CE%BB%CE%B1%CE%BD_%CE%A4%CE%BF%CF%8D%CF%81%CE%B9%CE%BD%CE%B3%CE%BA . [Πρόσβαση 3 6 2021].
- [9] A. M. Turing, Computing machinery and intelligence, Springer, 2009, p. 23–65.
- [10] A. L. Samuel, «Some studies in machine learning using the game of checkers,» *IBM Journal of research and development*, τόμ. 3, p. 210–229, 1959.
- [11] «www.ibm.com,» [Ηλεκτρονικό]. Available: <https://www.ibm.com/cloud/learn/machine-learning>. [Πρόσβαση 7 5 2021].
- [12] D. O. Hebb., Organization of Behavior, New York: John Wiley and Sons, Inc., 1949.

- [13] «[www.wikiwand.com](http://www.wikiwand.com/en/File:Components_of_neuron.jpg?fbclid=IwAR1Ke86n2iUqoXImvkHMHKBf4qZUuFLMrOAGxenGdWxl8SKoTmSedWuTSXI),» [Ηλεκτρονικό]. Available: https://commons.m.wikimedia.org/wiki/File:Components_of_neuron.jpg?fbclid=IwAR1Ke86n2iUqoXImvkHMHKBf4qZUuFLMrOAGxenGdWxl8SKoTmSedWuTSXI. [Πρόσβαση 5 6 2021].
- [14] W. S. McCulloch και W. Pitts, «A logical calculus of the ideas immanent in nervous activity,» *The bulletin of mathematical biophysics*, τόμ. 5, p. 115–133, 1943.
- [15] «www.wikipedia.com,» [Ηλεκτρονικό]. Available: https://en.wikipedia.org/wiki/Arthur_Samuel. [Πρόσβαση 3 5 2021].
- [16] «www.wikipedia.com,» [Ηλεκτρονικό]. Available: https://en.wikipedia.org/wiki/IBM_704. [Πρόσβαση 7 5 2021].
- [17] F. Rosenblatt, «Perceptron simulation experiments,» *Proceedings of the IRE*, τόμ. 48, p. 301–309, 1960.
- [18] «www.arm.com,» [Ηλεκτρονικό]. Available: <https://www.arm.com/glossary/pattern-recognition>. [Πρόσβαση 6 05 2021].
- [19] «www.wikipedia.com,» [Ηλεκτρονικό]. Available: https://en.wikipedia.org/wiki/Travelling_salesman_problem. [Πρόσβαση 6 5 2021].
- [20] «www.computerhistory.org,» [Ηλεκτρονικό]. Available: <https://www.computerhistory.org/revolution/artificial-intelligence-robotics/13/293/1277>. [Πρόσβαση 1 9 2021].
- [21] H. P. Moravec, «Obstacle avoidance and navigation in the real world by a seeing robot rover,» 1980.
- [22] G. DeJong και R. Mooney, «Explanation-based learning: An alternative view,» *Machine learning*, τόμ. 1, p. 145–176, 1986.
- [23] T. J. Sejnowski και C. R. Rosenberg, «Parallel networks that learn to pronounce English text,» *Complex systems*, τόμ. 1, p. 145–168, 1987.

- [24] «www.dataversity.net,» [Ηλεκτρονικό]. Available: <https://www.dataversity.net/a-brief-history-of-machine-learning/>. [Πρόσβαση 25 6 2021].
- [25] S. Hochreiter και J. Schmidhuber, «Long short-term memory,» *Neural computation*, τόμ. 9, p. 1735–1780, 1997.
- [26] A. Senior, H. Sak, F. de Chaumont Quitry, T. N. Sainath και K. Rao, «Acoustic Modelling with CD-CTC-SMBR LSTM RNNS,» σε *ASRU*, 2015.
- [27] G. E. Hinton και R. R. Salakhutdinov, «Reducing the dimensionality of data with neural networks,» *science*, τόμ. 313, p. 504–507, 2006.
- [28] «www.nist.gov,» [Ηλεκτρονικό]. Available: <https://www.nist.gov/programs-projects/face-recognition-grand-challenge-frgc>. [Πρόσβαση 7 5 2021].
- [29] «www.nytimes.com,» [Ηλεκτρονικό]. Available: https://www.nytimes.com/2012/06/26/technology/in-a-big-network-of-computers-evidence-of-machine-learning.html?_r=3&pagewanted=all. [Πρόσβαση 16 7 2021].
- [30] Y. Taigman, M. Yang, M. Ranzato και L. Wolf, «Deepface: Closing the gap to human-level performance in face verification,» σε *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2014.
- [31] «www.tesla.com,» [Ηλεκτρονικό]. Available: <https://www.tesla.com/AI>. [Πρόσβαση 19 7 2021].
- [32] M. M. Ahamad, S. Aktar, M. Rashed-Al-Mahfuz, S. Uddin, P. Liò, H. Xu, M. A. Summers, J. M. W. Quinn και M. A. Moni, «A machine learning model to identify early stage symptoms of SARS-Cov-2 infected patients,» *Expert systems with applications*, τόμ. 160, p. 113661, 2020.
- [33] J. O. Awoyemi, A. O. Adetunmbi και S. A. Oluwadare, «Credit card fraud detection using machine learning techniques: A comparative analysis,» σε *2017 International Conference on Computing Networking and Informatics (ICCNI)*, 2017.

- [34] R. Jhangiani, D. Bein και A. Verma, «Machine learning pipeline for fraud detection and prevention in e-commerce transactions,» σε *2019 IEEE 10th Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON)*, 2019.
- [35] S. Lalmuanawma, J. Hussain και L. Chhakchhuak, «Applications of machine learning and artificial intelligence for Covid-19 (SARS-CoV-2) pandemic: A review,» *Chaos, Solitons & Fractals*, τόμ. 139, p. 110059, 2020.
- [36] P. Larranaga, B. Calvo, R. Santana, C. Bielza, J. Galdiano, I. Inza, J. A. Lozano, R. Armananzas, G. Santafé, A. Pérez και others, «Machine learning in bioinformatics,» *Briefings in bioinformatics*, τόμ. 7, p. 86–112, 2006.
- [37] Q. Rao και J. Frtunikj, «Deep learning for self-driving cars: Chances and challenges,» σε *Proceedings of the 1st International Workshop on Software Engineering for AI in Autonomous Systems*, 2018.
- [38] C.-N. Ziegler, G. Lausen και L. Schmidt-Thieme, «Taxonomy-driven computation of product recommendations,» σε *Proceedings of the thirteenth ACM international conference on Information and knowledge management*, 2004.
- [39] A. Géron, «The machine learning landscape,» σε *Hands-On Machine Learning with Scikit-Learn & TensorFlow*, O'Reilly Media,, 2017, pp. 4-29.
- [40] «www.usgs.gov,» [Ηλεκτρονικό]. Available: https://www.usgs.gov/faqs/what-are-differences-between-data-a-dataset-and-a-database?qt-news_science_products=0#qt-news_science_products. [Πρόσβαση 3 4 2021].
- [41] [Ηλεκτρονικό]. Available: <https://chinchurosajolly.medium.com/machine-learning-cross-validation-3d4a95452640>. [Πρόσβαση 5 6 2021].
- [42] «www.machinelearningmastery.com,» [Ηλεκτρονικό]. Available: <https://machinelearningmastery.com/k-fold-cross-validation/>. [Πρόσβαση 5 7 2021].
- [43] «www.towardsdatascience.com,» [Ηλεκτρονικό]. Available: <https://towardsdatascience.com/confusion-matrix-for-your-multi-class-machine-learning-model-ff9aa3bf7826>. [Πρόσβαση 5 7 2021].

- [44] «www.dataschool.io,» [Ηλεκτρονικό]. Available: <https://www.dataschool.io/simple-guide-to-confusion-matrix-terminology/>. [Πρόσβαση 3 7 2021].
- [45] «www.medium.com,» [Ηλεκτρονικό]. Available: <https://medium.com/analytics-vidhya/notes-on-sensitivity-specificity-precision-recall-and-f1-score-e34204d0bb9b>. [Πρόσβαση 17 9 2021].
- [46] «www.dataschool.io,» [Ηλεκτρονικό]. Available: <https://www.dataschool.io/simple-guide-to-confusion-matrix-terminology/>. [Πρόσβαση 15 10 2021].
- [47] «www.machinelearningmastery.com,» [Ηλεκτρονικό]. Available: <https://machinelearningmastery.com/failure-of-accuracy-for-imbalanced-class-distributions/>. [Πρόσβαση 16 5 2021].
- [48] M. Duraipandian, «Performance evaluation of routing algorithm for Manet based on the machine learning techniques,» *Journal of trends in Computer Science and Smart technology (TCSST)*, τόμ. 1, p. 25–38, 2019.
- [49] S. Ghasemnezhad και A. Ghaffari, «Fuzzy logic based reliable and real-time routing protocol for mobile ad hoc networks,» *Wireless Personal Communications*, τόμ. 98, p. 593–611, 2018.
- [50] S. M. Darwish, A. Elmasry και S. H. Ibrahim, «Optimal shortest path in mobile ad-hoc network based on fruit fly optimization algorithm,» σε *International Conference on Advanced Machine Learning Technologies and Applications*, 2019.
- [51] S. Chaudhary και R. Johari, «ORuML: Optimized routing in wireless networks using machine learning,» *International Journal of Communication Systems*, τόμ. 33, p. e4394, 2020.
- [52] «www.bluetooth.com,» [Ηλεκτρονικό]. Available: <https://www.bluetooth.com/learn-about-bluetooth/tech-overview/>. [Πρόσβαση 6 5 2021].
- [53] Y. Z. T. V. S. Athanasios V. Vasilakos, σε *Delay Tolerant Networks: Protocols and Applications*, CRC Press, 2016, pp. 2-7.

- [54] «www.nasa.gov,» 29 9 2020. [Ηλεκτρονικό]. Available: https://www.nasa.gov/directorates/heo/scan/engineering/technology/disruption_tolerance_networking. [Πρόσβαση 6 5 2021].
- [55] S. L. David W. Hosmer, «8.1 THE MULTINOMIAL LOGISTIC REGRESSION,» σε *Applied Logistic Regression Second Edition*, Columbus , Ohio, JOHN WILEY & SONS, INC., 2013, pp. 260-264.
- [56] «www.towardsdatascience.com,» [Ηλεκτρονικό]. Available: <https://towardsdatascience.com/machine-learning-basics-with-the-k-nearest-neighbors-algorithm-6a6e71d01761>. [Πρόσβαση 4 6 2021].
- [57] M. S. A. K. V. K. Pang-Ning Tan, «4.3 Κατηγοριοποιητές Πλησιέστερου Γείτονα,» σε *Εισαγωγή στην εξόρυξη δεδομένων ,2η έκδοση*, Εκδοσεις Τζιόλα, 2018, pp. 147-150.
- [58] R. Dudukovich και C. Papachristou, «Delay tolerant network routing as a machine learning classification problem,» σε *2018 NASA/ESA Conference on Adaptive Hardware and Systems (AHS)*, 2018.
- [59] «4.4 Ο Απλοϊκός κατα Bayes Κατηγοριοποιητής,» σε *Εισαγωγή στην εξόρυξη δεδομένων, 2η έκδοση*, Εκδόσεις Τζιόλα, 2018, pp. 151-160.
- [60] «www.geeksforgeeks.com,» [Ηλεκτρονικό]. Available: <https://www.geeksforgeeks.org/decision-tree/> .. [Πρόσβαση 6 7 2021].
- [61] M. S. A. K. V. K. Pang-Ning Tan, «3.3 Κατηγοριοποιητής Δένδρου Απόφασης,» σε *Εισαγωγή στην εξόρυξη δεδομένων*, Εκδόσεις Τζιόλα , 2018, pp. 57-98.
- [62] L. Guo και I. Matta, «The war between mice and elephants,» p. 180–188, 2001.
- [63] P. Poupart, Z. Chen, P. Jaini, F. Fung, H. Susanto, Y. Geng, L. Chen, K. Chen και H. Jin, «Online flow size prediction for improved network routing,» p. 1–6, 2016.
- [64] J. A. B.K. Tripathy, «Preface,» σε *Internet Of Things(IOT),Technologies, Applications,Challenges, and Solutions*, CRC Press, 2018, pp. ix-xiii.

- [65] V. Vashishth, A. Chhabra και D. K. Sharma, «GMMR: A Gaussian mixture model based unsupervised machine learning approach for optimal routing in opportunistic IoT networks,» *Computer Communications*, τόμ. 134, p. 138–148, 2019.
- [66] N. G. Palan, B. V. Barbadekar και S. Patil, «Low energy adaptive clustering hierarchy (LEACH) protocol: A retrospective analysis,» σε *2017 International conference on inventive systems and control (ICISC)*, 2017.
- [67] F. Khan, S. Memon και S. H. Jokhio, «Support vector machine based energy aware routing in wireless sensor networks,» p. 1–4, 2016.
- [68] «[www.towardsdatascience.com,](http://www.towardsdatascience.com/support-vector-machine-introduction-to-machine-learning-algorithms-934a444fca47)» [Ηλεκτρονικό]. Available: <https://towardsdatascience.com/support-vector-machine-introduction-to-machine-learning-algorithms-934a444fca47> . [Πρόσβαση 23 5 2021].
- [69] A. C. Ingo Steinwart, «1.2 Support Vector Machines: An Overview,» σε *Support Vector Machines* , Springer, New York, NY, 2008, pp. 7-13.
- [70] A. C. Ingo Steinwart, «1.3 History of SVMs and Geometrical Interpretation,» σε *Support Vector Machines* , Springer, New York, NY, 2008, pp. 13-19.
- [71] H. Σχισμένος, «[www.estia.hua.gr,](http://www.estia.hua.gr)» [Ηλεκτρονικό]. Available: <http://estia.hua.gr/file/lib/default/data/17906/theFile>. [Πρόσβαση 16 7 2021].
- [72] Z. M. Fadlullah, F. Tang, B. Mao, N. Kato, O. Akashi, T. Inoue και K. Mizutani, «State-of-the-art deep learning: Evolving machine intelligence toward tomorrow’s intelligent network traffic control systems,» *IEEE Communications Surveys & Tutorials*, τόμ. 19, p. 2432–2455, 2017.
- [73] H. Yao, X. Yuan, P. Zhang, J. Wang, C. Jiang και M. Guizani, «Machine learning aided load balance routing scheme considering queue utilization,» *IEEE Transactions on Vehicular Technology*, τόμ. 68, p. 7987–7999, 2019.
- [74] L. Hanzo και R. Tafazolli, «A survey of QoS routing solutions for mobile ad hoc networks,» *IEEE Communications Surveys & Tutorials*, τόμ. 9, p. 50–70, 2007.

- [75] «www.techtarget.com,» [Ηλεκτρονικό]. Available: <https://www.techtarget.com/searchnetworking/definition/edge-device>. [Πρόσβαση 6 5 2021].
- [76] G. Zhu, D. Liu, Y. Du, C. You, J. Zhang και K. Huang, «Toward an intelligent edge: Wireless communication meets machine learning,» *IEEE communications magazine*, τόμ. 58, p. 19–25, 2020.
- [77] «www.wikipedia.com,» [Ηλεκτρονικό]. Available: [https://en.wikipedia.org/wiki/Coverage_\(telecommunication\)](https://en.wikipedia.org/wiki/Coverage_(telecommunication)). [Πρόσβαση 7 5 2021].
- [78] H. El Hammouti, M. Ghogho και S. A. R. Zaidi, «A machine learning approach to predicting coverage in random wireless networks,» σε *2018 IEEE Globecom Workshops (GC Wkshps)*, 2018.
- [79] «www.qualcomm.com,» [Ηλεκτρονικό]. Available: <https://www.qualcomm.com/5g/what-is-5g>. [Πρόσβαση 15 7 2021].
- [80] «www.cisco.com,» [Ηλεκτρονικό]. Available: <https://www.cisco.com/c/en/us/solutions/what-is-5g.html#~faq>. [Πρόσβαση 25 8 2021].
- [81] «www.rapid7.com,» [Ηλεκτρονικό]. Available: <https://www.rapid7.com/fundamentals/spoofing-attacks/>. [Πρόσβαση 15 7 2021].
- [82] «www.avast.com,» [Ηλεκτρονικό]. Available: <https://www.avast.com/c-spoofing#gref>. [Πρόσβαση 15 9 2021].
- [83] N. Wang, J. Tang και K. Zeng, «Spoofing attack detection in mm-wave and massive MIMO 5G communication,» σε *2019 IEEE Conference on Communications and Network Security (CNS)*, 2019.
- [84] «www.geeksforgeeks.com,» [Ηλεκτρονικό]. Available: <https://www.geeksforgeeks.org/difference-between-parametric-and-non-parametric-methods/>. [Πρόσβαση 15 08 2021].

- [85] P. N. Stuart J. Russell, σε *Artificial Intelligence: A Modern Approach*, Pearson, 2015, p. 737.
- [86] P. N. Stuart J. Russel, σε *Artificial Intelligence: A Modern Approach*, Pearson, 2015, p. 757.
- [87] H. Fang, X. Wang και S. Tomasin, «Machine learning for intelligent authentication in 5G and beyond wireless networks,» *IEEE Wireless Communications*, τόμ. 26, p. 55–61, 2019.

